

Sveučilište u Zagrebu  
**Fakultet strojarstva i brodogradnje**

# **DIPLOMSKI RAD**

Tomislav Baljak

Zagreb, 2009



Sveučilište u Zagrebu  
**Fakultet strojarstva i brodogradnje**

# **PROCJENA KRETANJA PREDMETA RADA VIZIJSKIM SUSTAVOM**

Voditelj rada:

Prof. dr. sc. Bojan Jerbić

Tomislav Baljak

Zagreb, 2009





# Izjava

Izjavljujem pod punom materijalnom i moralnom odgovornošću da sam diplomski rad izradio samostalno, isključivo znanjem stečenim na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu, uz pomoć prof. dr. sc. Bojana Jerbića kojem se ovim putem zahvaljujem, te literaturom navedenom u popisu referenci. Također se zahvaljujem dipl. ing. Tomislavu Stipančiću i dipl. ing Petru Čurkoviću na njihovoj nesebičnoj pomoći i naputcima prilikom izrade ovog projekta.

U Zagrebu, 2009.



# SADRŽAJ

<b>POPIS SLIKA .....</b>	<b>III</b>
<b>POPIS TABLICA .....</b>	<b>V</b>
<b>POPIS OZNAKA.....</b>	<b>VI</b>
<b>SAŽETAK .....</b>	<b>VII</b>
<b>1. UVOD.....</b>	<b>1</b>
1.1 Povijesna perspektiva .....	1
1.2 Razvoj vizijskih sustava.....	4
<b>2. OSNOVNE ZNAČAJKE SVIJETLOSTI .....</b>	<b>5</b>
2.1 Ljudski vizijski sustav .....	5
2.2 Radijacija i iluminacija .....	7
2.3 Interakcija zračenja sa materijom.....	9
<b>3. VIZIJSKI SUSTAVI.....</b>	<b>11</b>
3.1 Usporedba ljudskog vida i umjetnih sustava .....	11
3.2 Koncept izrade vizijskog sustava .....	13
3.2.1 Definiranje vizijskog sustava .....	14
3.2.2 Kreiranje vizijskog sustava .....	17
3.2.3 Troškovi .....	28
<b>4. OSNOVE OBRADE I AKVIZICIJE SLIKE.....</b>	<b>30</b>
4.1 Obrada slike .....	30
4.2 Akvizicija slike .....	32
4.3 Parametri stvaranja slike .....	33
4.4 Senzor slike.....	34
4.5 Slika.....	36
4.6 Analiza slike .....	38
4.6.1 Detekcija rubova .....	39
4.6.2 Traženje uzorka .....	40
4.6.3 Traženje geometrijskih značajki .....	41
4.6.4 Mjerenje dimenzija.....	43

<b>5. TEHNIČKE KARAKTERISTIKE SUSTAVA .....</b>	<b>45</b>
5.1 Kamera.....	49
5.2 Procesorska jedinica vizijskog sustava .....	51
5.3 I/O Modul.....	55
5.4 Ostale hardverske komponente .....	57
5.5 Predmet rada.....	61
<b>6. VIZIJSKI PROCES .....</b>	<b>62</b>
6.1 Podešavanje vizijskog sustava i kalibracija.....	63
6.2 Opis procesa .....	67
6.3 VBAI sučelje .....	70
6.4 Izrada algoritma.....	73
6.5 PLC tajmer .....	79
6.6 Rezultati mjerenja.....	80
<b>7. ZAKLJUČAK.....</b>	<b>84</b>
<b>LITERATURA.....</b>	<b>86</b>

# POPIS SLIKA

Slika 1.1 Sustav za prepoznavanje nepravilnosti na krumpirićima [1] .....	2
Slika 1.2 Cognex's sustav za ispitivanje LCD ekrana [1] .....	3
Slika 1.3 Rana verzija sustava za kontrolu kvalitete lakiranja [1] .....	4
Slika 2.1 Lanac procesiranja informacija .....	5
Slika 2.2 Prihvat svjetlosti ljudskog oka .....	6
Slika 2.3 Vanjski dijelovi oka .....	6
Slika 2.4 Ljudski vizualni sustav nadopunjava nepostojeću informaciju .....	7
Slika 2.5 Spektar elektromagnetskog zračenja .....	8
Slika 2.6 Vidljivi dio spektra .....	8
Slika 2.7 Lanac zračenja [2] .....	9
Slika 2.8 Figurativni prikaz refrakcije .....	10
Slika 3.1 Zahtjevi za procesorskim vremenom [2] .....	15
Slika 3.2 Smjerovi skeniranja lijsjckog skenera .....	17
Slika 3.3 Pokrivenost scene [2] .....	18
Slika 3.4 Područja osvijetljena objektivom i kamerom [2] .....	23
Slika 3.5 Prikaz prednjeg (a) i stražnjeg (b) osvijetljenja .....	24
Slika 3.6 Ilustracija različitih postavki rasvjete [3] .....	25
Slika 4.1 Nivoi obrade slike .....	31
Slika 4.2 Lanac elemenata u procesu akvizicije slike [3] .....	32
Slika 4.3 Prikaz stvaranja slike .....	33
Slika 4.4 Građa senzora slike .....	34
Slika 4.5 Rad senzora slike .....	35
Slika 4.6 Pikseli sadržani u slici .....	36
Slika 4.7 Matrica slike i pripadajuća slika [4] .....	37
Slika 4.8 Osnova procesa analize slike .....	38
Slika 4.9 Primjer detekcije rubova [5] .....	39
Slika 4.10 Model ruba [6] .....	40
Slika 4.11 Traženje uzorka [6] .....	41
Slika 4.12 Primjeri značajki za geometrijsko prepoznavanje [6] .....	42
Slika 4.13 Geometrijske informacije korištene za prepoznavanje [6] .....	42
Slika 4.14 Mjerenje dimenzija značajki objekta [6] .....	43
Slika 5.1 Komponente sustava .....	45
Slika 5.2 Shematski prikaz rada vizijskog sustava .....	46
Slika 5.3 Shematski prikaz rada cjelokupnog sustava .....	48
Slika 5.4 Osnovne dimenzije kamere [7] .....	50
Slika 5.5 Položaj kamere u montažnom sustavu .....	50
Slika 5.6 CVS-1450 Series prednja ploča [8] .....	51
Slika 5.7 Osnovne dimenzije CVS-1450 Series modula [8] .....	52
Slika 5.8 Shematski prikaz povezivanja CVS 1450 modula .....	53
Slika 5.9 Položaj CVS 1450 modula u montažnom sustavu .....	54
Slika 5.10 NI Vision I/O Accessory prednja ploča [9] .....	55
Slika 5.11 Položaj I/O Accessory modula u montažnom sustavu .....	56
Slika 5.12 Kapacitivni senzor .....	57

Slika 5.13 Položaj senzora blizine u montažnom sustavu .....	58
Slika 5.14 Allen Bradley L32E PLC .....	59
Slika 5.15 Prikaz objektiva .....	60
Slika 5.16 Dimenzije sklopke i palete .....	61
Slika 5.17 Prikaz sklopke na paleti .....	61
Slika 6.1 Prikaz tumačenja slike NI vizijskog sustava [10].....	63
Slika 6.2 Osnovni parametri vizijskog sustava [10].....	64
Slika 6.3 Kut kamere u odnosu na predmet promatranja [10] .....	65
Slika 6.4 Pogreška nastala zbog percepcije i distorzije .....	65
Slika 6.5 Proces kalibracije .....	66
Slika 6.6 Ishodište i zakret koordinatnog sustava .....	66
Slika 6.7 Redosljed izvršavanja radnji pri praćenju predmeta rada .....	67
Slika 6.8 Glavne varijable sustava .....	68
Slika 6. 9 VBAI konfiguracijsko sučelje [10] .....	70
Slika 6.10 VBAI inspekcijsko sučelje [10] .....	71
Slika 6.11 Osnovni modovi konfiguracijskog sučelja .....	72
Slika 6.12 Glavni dijagram toka .....	73
Slika 6.13 Koraci procesa akvizicije slike .....	74
Slika 6.14 Koraci procesa obrade slike.....	75
Slika 6.15 Područje pretraživanja .....	76
Slika 6.16 Definiranje geometrijske značajke .....	77
Slika 6.17 Blok dijagram modela kalkulatora .....	78
Slika 6.18 Osnovni koraci u Ladder dijagramu .....	79
Slika 6.19 Grafički prikaz rasipanja rezultata mjerenja puta .....	80
Slika 6.20 Grafički prikaz rasipanja rezultata mjerenja vremena .....	81

## POPIS TABLICA

Tablica 3.1 Procjena performansi .....	11
Tablica 3.2 Procjena mogućnosti.....	12
Tablica 3.3 Očekivana točnost u ovisnosti o algoritmu .....	20
Tablica 3.4 Popis varijabli za izračun rezolucije .....	20
Tablica 3.5 Varijable brzine prijenosa piksela.....	22
Tablica 3.6 Brzina prijenosa podataka različitim sučeljima .....	22
Tablica 4.1 Klasifikacija obrade slike .....	30
Tablica 5.1 Specifikacije kamere Basler Scout [7].....	49

## POPIS OZNAKA

$R_s$	mm/piksel	- prostorna rezolucija
$R_c$	piksel	- rezolucija kamere
$S_f$	mm	- veličina najmanje značajke
$N_f$	mm	- broj piksela značajke
PR	piksel/s	- brzina prijenosa piksela
$R_{c_{hor}}$	piksel	- horizontalna rezolucija kamere
$R_{c_{ver}}$	piksel	- verikalna rezolucija kamere
$f_r$	Hz	- broj slika
$t_1$	s	- definirano vrijeme između akvizicija
$s_1$	mm	- izračunati put
$t_2$	s	- vrijeme između aktivacija senzora
$s_2$	mm	- put pređen za vrijeme $t_2$
$\Delta t$	s	- ukupno vrijeme
$s_{VS}$ srednje	mm	- srednja vrijednost mjerenog puta
$t_{VS}$ zadano	s	- vrijeme između akvizicije dvije slike
$s$ mjereno	mm	- udaljenost između senzora
$t$ mjereno	s	- izmjereno vrijeme između aktivacije senzora
$v_{VS}$ objektivno	mm/s	- brzina gibanja predmeta rada



# SAŽETAK

U ovom radu obrađuje se problematika primjene vizijskog sustava za procjenu kretanja predmeta rada. U radu je potrebno dostupnim vizijskim sustavom National Instruments NI CVS 1450 i ostalim raspoloživim sredstvima izvršiti mjerenje brzine kretanja predmeta rada. Isto tako potrebno je izvršiti objektivno mjerenje nekim od dostupnih sustava kako bi se utvrdila odstupanja u mjerenju kod vizijskog sustava i kako bi se izračunala veličina greške koju generira vizijski sustav. Na taj način bi se eventualno vizijski sustav mogao primijeniti za dinamičko upravljanje robotom pri izvođenju operacija sklapanja.

Rad je podijeljen u sedam poglavlja. U prvom poglavlju kratko su opisani razvoj vizijskih sustava, dan je osvrt na povijesnu perspektivu te je ukratko objašnjeno što vizijski sustavi predstavljaju u industriji. U slijedećem poglavlju opisan je proces računalne vizije, opisan je ljudski vizijski sustav, njegova građa i značenje u odnosu na umjetne sustave. Objašnjeni su pojmovi elektromagnetskog zračenja, definicija svjetlosti te interakcija svjetlosti sa materijom te su dani pregledi osnovnih parametara i pojmova koji se susreću u području umjetnih vizijskih sustava. Sve su to procesi koji predstavljaju osnove vizijskih sustava. U trećem poglavlju definiran je pojam vizijskog sustava, dana je kratka usporedba ljudskog vizijskog sustava i umjetnih sustava te su dane osnovne predosti i nedostaci jednih i drugih. Dalje je opisan koncept izrade vizijskih sustava u koji su uključeni definiranje vizijskog sustava, kreiranje vizijskog sustava i ostalo. Pokriveni su svi aspekti od potrebnih dijelova, zahtijeva za performansama, vrsta kamera, scene, hardverskih platformi, mehaničke konstrukcije, električne konstrukcije, softvera, troškova i ostalih čimbenika. U četvrtom poglavlju opisane su osnove obrade i akvizicije slike te osnovni pristupi navedenoj tematici. Objašnjen je proces obrade slike pri čemu se obradilo područje akvizicije slike i parametri stvaranja slike. Obrađene su osnove senzora slike, i njihova funkcija te princip rada. Objašnjen je proces nastanka digitalne slike, njena analiza te osnovni alati kojima se slika obrađuje. U petom poglavlju detaljno se obradio sustav na kojem se radiila procjena kretanja predmeta rada. Opisani su svi elementi sustava te su dane njihove specifikacije, opisana je njihova funkcija u sustavu i način rada. U šestom poglavlju detaljno je obrađena problematika ovog rada, a to je procjena kretanja predmeta rada. Analiziran je algoritam koji nadzire proces te su definirani svi parametri algoritma. Teme koje su obrađene uključuju kalibraciju sustava, opis cjelokupnog procesa vizijskog sustava i detaljan opis VBAI sučelja u kojem je izrađen algoritam koji upravlja vizijskim procesom. Na kraju su prikazani rezultati mjerenja koji su izvršeni nakon sklapanja cijelog sustava te programiranja potrebnih aplikacija. U zadnjem poglavlju su sumirani rezultati ovoga rada te su dana moguća rješenja i prijedlozi mogućih poboljšanja za eventualnu daljnju primjenu.



# 1. UVOD

U industrijskoj primjeni su danas neophodni sustavi koji nude automatizirani nadzor i metode kontrole i obrade koje garantiraju kvalitetu. Metode su dostupne već danas, a jedna od tih metoda su upravo vizijski sustavi. Oni mogu biti integrirani u sve proizvodne procese: prihvatanje, formiranje, sklapanje, skladištenje, dostava i dr. Ipak, sam hardver ne bi trebao biti glavna preokupacija kod kreiranja takvih sustava već i uloga softvera igra iznimno značajnu ulogu. Podatci koji pristižu iz takvih vizijskih sustava su osnova za integriranu proizvodnju podržanu računalom (CIM).

Podatci o proizvodnji utječu na kvalitetu, a ne obrnuto. Većina podataka koji pristižu u proizvodnji zahtijeva nadzor u smislu kontrole kvalitete van tradicionalnih aspekata, gdje se motre pojedini dijelovi, u područja kao što su dizajn, konstrukcija, planiranje procesa i proizvodnja. Da bi podatci imali utjecaj na proizvodnju moraju biti što je više moguće točni i precizni. Kada su pravilno implementirani, vizijski sustavi mogu automatizirati akviziciju podataka te mogu služiti kao referenca u kontroli procesa. Snimanjem tih podataka automatski, izravno sa vizijskih sustava ulazne greške su značajno smanjene, a ljudska interakcija minimizirana. Prednosti tako koncipiranih sustava uključuju:

- Smanjeni izravni rad
- Smanjeni neizravni rad
- Smanjeni troškovi
- Povećano korištenje opreme
- Povećana fleksibilnost
- Reducirani inventar
- Reducirani otpad
- Reducirana vremena rada
- Reducirana pripremna vremena
- Optimizirana proizvodna ravnoteža
- Reducirani troškovi manipulacije materijalom i oštećenja.


## 1.1 Povijesna perspektiva

Koncept strojnog vida, odnosno računalnih vizijskih sustava seže još u davne tridesete godine prošlog stoljeća. Tvrtka Electronic Sorting Machines je nudila uređaje za sortiranje hrane bazirane na specifičnim filterima i fotoelementima kao detektorima. Tvrtka postoji još i danas i nudi uređaje istih namjena. Njihovi uređaji bili su jedni od prvih u industriji koji su koristili, doduše primitivne, vizijske sustave u industrijskoj primjeni.

Četrdesetih godina u SAD-u je krenula intenzivna akcija povrata plastičnih boca za reciklažu. U to vrijeme razvijeni su vizijski sustavi koji su služili za inspekciju boca i provjeru čistoće pojedinih boca. Takvi sustavi koristili su pametnu optiku i fotoelemente kao detektore. Kao i ranije tehnologije i ova je bila popuno analogno bazirana. Samih sustava je bilo instalirano više od 3000 čime je počela intenzivna primjena u inustrijske svrhe.


Područje računalne vizije i strojnog vida je napredovalo usporedo sa napretkom računala i njihovom primjenom u industriji. Pedesetih godina naglo je počeo razvoj prepoznavanja uzoraka i analiza koja je bila potaknuta sponzorstvom nacionalnih zdravstvenih instituta budući su se upravo ti algoritmi i sustavi koristili za analizu kromosoma i dijagnosticiranje raznih nepravilnosti u krvi i raznim tkivima.

Šezdesetih godina vojska je poticala intenzivna istraživanja i razvoj (R&D) sustava koji su služili za automatsku interpretaciju nadzornih fotografija kao i sustava za automatsko traženje i praćenje meta. Tada se mnogo vremena posvetilo istraživanjima ljudskog vida i kako točno funkcionira ljudski vid, sve sa ciljem ne bi li se jednoga dana stečena znanja primjenila na računalnu viziju. Doba je to kada je počela i prva digitalizacija video snimaka. Prvotni koncepti sastojali su se u tome da se hvataju elektromagnetski valovi pomoću skenera. Nakon toga bi se signal digitalizirao te koristilo računalo kako bi se dobiveni rezultat usporedio sa onim pohranjenim u memoriji računala. 1965. godine izrađen je upravo takav uređaj. U osnovi, digitaliziran je jedan piksel po liniji za svaki sken. Drugim riječima, bilo je potrebno 500 skenova kako bi se digitalizirala cijela slika.



Slika 1.1 Sustav za prepoznavanje nepravilnosti na krumpirićima [1]

Ranih sedamdesetih počeo je snažan rast snage mikroprocesora, rasle su performanse dok su se troškovi smanjivali. Istodobno bio je očigledan napredak na području optičkih vlakana, lasera i kamera. Sredinom sedamdesetih počeo je i razvoj prvih 3D skenera. Tada je počela ponuda uređaja koje sa pravom možemo nazvati vizijski sustavi i to u formi u kakvoj ih danas poznajemo. Tada su sustavi bili specijalizirani kako bi izvršavali jedan, i to samo jedan zadatak, kontroliranje kvalitete krumpirića (Slika 1.1). Uslijedili su sustavi koji su mogli izvršavati i više zadataka, primjena je počela u proizvodnji pouzdanih. Ubrzo su razvijeni i prvi sustavi koji su se mogli navoditi vizijskim sustavom. Jedan od njih je bio robot vođen vizijskim sustavom koji je služio za skupljanje predmeta rada. Osamdesetih godina je definiran termin "machine vision" te je postao prihvaćeni naziv za tu tehnologiju. Tada je već cijela industrija vizijskih sustava bila vrlo zrela. Daljnji nezaustavljivi razvoj mikroprocesora i kamera kao i pad cijena osnovnih komponenata omogućavali su neprekidan rast industrije i primjene vizijskih sustava. Do kraja osamdesetih svaka ključna grana u industriji je imala specijalizirane vizijske sustave za vlastite potrebe. Od 1980, oko 100 tvrtki je ponudilo razne fleksibilne vizijske sustave kako bi se zadovoljile specifične potrebe pojedinih grana industrije (Slika 1.2).




Slika 1.2 Cognex's sustav za ispitivanje LCD ekrana [1]

## 1.2 Razvoj vizijskih sustava

Većina vizijskih sustava je evoluiralo na osnovu ideje kako radi ljudski vid. Iz toga proizlazi da iako sustav može biti prilično dobro prilagođen nekim specifičnim zadacima, performanse ostvarene prilikom izvođenja drugih zadataka će zadovoljiti samo u idealnim uvjetima. Stoga, virtualno svaka aplikacija uključuje eksperimentiranje sa uzorcima kako bi se utvrdilo da li zadatak može biti pravilno obavljen.


Napredak u elektronici omogućio je tehničku isplativost i izvedivost uporabe vizijskih sustava u mnogim primjenama. Mikroelektronika je rezultirala poboljšanim senzorima za akviziciju slike, memorijom veće gustoće i bržim mikroracionalima. Napredak u razvoju osobnih računala je omogućio dovoljno brzo izvršavanje zahtjevnih algoritama vizijskih sustava za mnoge aplikacije. Proboj Windows™ baziranih grafičkih korisničkih sučelja (GUI) rezultirao je u jednostavnijoj primjeni i korištenju navedenih sustava. Istovremeno, troškovi povezani sa unaprijeđenim sustavima i tehnologijama su se smanjili što je omogućilo povoljno uvođenje novih tehnologija. Takav trend se nastavlja i dalje te uvođenje vizijskih sustava u svakodnevnu primjenu postaje iznimno isplativo (Slika 1.3).



Slika 1.3 Rana verzija sustava za kontrolu kvalitete lakiranja [1]

## 2. OSNOVNE ZNAČAJKE SVIJETLOSTI

Cijeli proces u sustavima računalne vizije se smatra integralnim postupkom, od formiranja slike, mjerenja, prepoznavanja ili nekakve reakcije. Računalna vizija se opisuje kao skup tehnika za akviziciju, procesiranje, analizu i razumijevanje kompleksnih višedimenzijskih podataka iz okoliša za znanstvenu i tehničku upotrebu.




Slika 2.1 Lanac procesiranja informacija

### 2.1 Ljudski vizijski sustav

Kao i kod bilo koje kamere, prvi korak u viziji jest projekcija vizualne scene na niz fotodetektora. Kod ljudskog vida upravo oko ima tu funkciju (Slika 2.2). U


konačnici samo oko 10% svjetlosti zaista i stigne do mrežnice koja ima ulogu prihvata svjetlosti i konverzije u električni signal.



Slika 2.2 Prihvat svjetlosti ljudskog oka

Projicirana slika se prvo analizira na mrežnici oka nakon što prođe kroz optički sustav oka (Slika 2.3). Optička os oka nije savršeno definirana stoga što rubovi leća nisu rotacijski simetrični i nisu centrirani na jednoj osi. No iako se može pomisliti kako je kvaliteta slike najveća blizu optičke osi to nije točno stoga što bjeloočnica nije centrirana u odnosu na optičku os. Sam kut je relativan i ovisi o položaju oka iz čega proizlazi da je slika vrlo dobra i izvan optičke osi.

Zbog same građe oka ono je baš kao i umjetni vizijski sustavi podložno kromatskim i akromatskim aberacijama. To su pojave koje disperiraju svjetlost na razne načine pa zbog građe optičkog sustava oka svjetlost koja pada na fotodetektore, u ovom slučaju mrežnicu, rezultira u brojnim artefaktima. Unatoč tome, ljudski vizijski sustav je jedan od najsavršenijih u prirodi.




Slika 2.3 Vanjski dijelovi oka



Različitosti koje ljudski vid može percipirati su nekada vrlo ograničene.

- Raspon svjetline na koju se ljudsko oko može priviknuti je vrlo velika
- Vizualni sustav ne radi istovremeno u cijelom rasponu svjetline
- Ljudski sustav je osnova i služi kao model za umjetne sustave
- Raspon svjetlina koje se istovremeno mogu razlikovati je vrlo malen


No ono u čemu ljudski vizijski sustav odmiče od svih umjetnih sustava i gdje dominira je adaptivnost. Razloge treba tražiti u milijunima godina evolucije. Ljudski vizijski sustav je lanac koji se sastoji od mnoštva organa, no same informacije koje sustav prikuplja bile bi beskorisne bez sustava koji ih obrađuje, mozga. Zbog toga ljudski vid odmiče svojim sposobnostima od umjetnih sustava. Takva adaptivnost stvara ogromne prednosti, no u malom broju slučajeva može biti i nedostatak (Slika 2.4).



Slika 2.4 Ljudski vizualni sustav nadopunjava nepostojeću informaciju

## 2.2 Radijacija i iluminacija

Elektromagnetsko zračenje (Slika 2.5) se sastoji od elektromagnetskih valova koji nose neku energiju te se gibaju kroz prostor. Valna duljina i frekvencija valova su povezani sa brzinom svjetlosti  $c$ , pa je ona jednaka umnošku valne duljine i frekvencije. Brzina svjetlosti ovisi o mediju kroz koji se svjetlost giba i iznosi  $2.9979 \times 10^8 \text{ ms}^{-1}$  prilikom gibanja kroz vakuum.




Slika 2.5 Spektar elektromagnetskog zračenja

Svjetlost je elektromagnetsko zračenje valne duljine koja je vidljiva ljudskom oku (između 400 i 700 nm) (Slika 2.6). Osnovna svojstva svjetlosti su:

- Intenzitet
- Frekvencija ili valna duljina
- Polarizacija
- Faza

Svjetlost dolazi u malenim paketima zvanima fotoni. Posjeduje svojstva i valova i čestica, a to svojstvo je znano kao dvojna priroda svjetlosti.




Slika 2.6 Vidljivi dio spektra

## 2.3 Interakcija zračenja sa materijom

Vizualizacija u računalnoj viziji zahtjeva znanja fizikalnih svojstava objekata koji su u sklopu promatranja kao i optička svojstva sustava za akviziciju slike. Fizikalna svojstva kao što su penetracijska dubina ili reflektivnost površine su esencijalna za poznavanje strukture objekata, geometrije scene i svojstava površine. Svojstva fizičkih objekata stoga, ne samo da mogu biti detektirana u geometrijskoj distribuciji emitiranog zračenja već i u djelu radijacije koja je emitirana, raspršena, apsorbirana ili reflektirana te naposljetku zabilježena vizijskim sustavom (Slika 2.7).

Većina procesa je osjetljiva na specifične valne duljine i dodatne informacije mogu biti skrivene u spektralnoj distribuciji zračenja. Korištenjem različitih vrsta radijacije omogućavamo akviziciju slika različitih dubina ili prikupljanje različitih svojstava promatranih objekata.




Slika 2.7 Lanac zračenja [2]

Zračenje koje se odbija od ili prolazi kroz objekte je podložno raznim procesima promjene smjera propagacije, atenuacije ili pojačanja intenziteta zračenja te promjene spektralne distribucije ili polarizacije zračenja. Bez ulazjenja u detalje kompleksnih fizičkih procesa može se definirati nekoliko osnovnih parametara koji su bitni u opisivanju optičkih svojstava:

- Reflektivnost – mjera djela pojačanja reflektiranog elektromagnetskog polja, dio zračenja reflektiran od površine
- Apsorpcija – dio zračenja apsorbiran uzorkom pri specifičnoj valnoj duljini
- Transmisija – dio zračenja određene valne duljine koji prolazi kroz uzorak

- Emisija – omjer energija koje zrači specifično tijelo i energije koje zrači crno tijelo pri istoj temperaturi

Uz navedena svojstva, bitno je napomenuti i jedan od važnijih parametara površine o kojemu ovisi interferencija zračenja, a samim time i rezultat koji prima vizijski sustav. Refrakcija je omjer brzine svjetlosti u vakuumu i brzine svjetlosti u mediju kojega promatramo. Ona definira promjenu smjera propagacije zračenja na prijelazu iz jednog medija u drugi (Slika 2.8).



Slika 2.8 Figurativni prikaz refrakcije

### 3. VIZIJSKI SUSTAVI

Vizijski sustavi odnosno aplikacije vezane uz analizu i obradu slike potpomognute računalom su tehnologija koja je značajno doprinjela poboljšanju produktivnosti proizvodnih operacija i procesa u gotovo svakoj industriji. U nekim industrijama proizvodnja je jednostavno nezamisliva bez umjetnih vizijskih sustava.

**Strojni vid** (Machine vision) je izraz koji označava spajanje jedne ili više tehnologija detekcije i računalnih tehnologija. U osnovi senzor, koji je uobičajeno neka vrsta kamere, prikuplja elektromagnetsku energiju unutar scene, najčešće zračenje u vidljivom dijelu spektra i konvertira tu energiju u sliku koju računalno može interpretirati. Računalno potom ekstraktira podatke iz slike, uspoređuje te podatke sa prethodno definiranim standardima i generira rezultat, najčešće u obliku nekakvog odziva. [1]

#### 3.1 Usporedba ljudskog vida i umjetnih sustava

Iako se danas može i očekivati, strojni vid, odnosno umjetni vizijski sustavi nemaju sposobnosti i performanse kakve bi se mogle očekivati od naprednih umjetnih sustava (Tablica 3.1, Tablica 3.2). Optički živci u svakom oku rastavljaju sliku u otprilike milijun zasebnih polja podataka. Sama mrežnica se pak ponaša poput ekvivalentnih 1000 slojeva vizijskih procesora slike. Svaki sloj djelomično obrađuje sliku i šalje je dalje.

Tablica 3.1 Procjena performansi

PERFORMANSE	UMJETNI SUSTAVI	LJUDSKI VID
REZOLUCIJA	Limitirana poljem piksela	Visoka rezolucija
BRZINA PROCESIRANJA	Djelić sekunde po slici	U stvarnom vremenu
RAZLUČIVOST	Limitirano na slike visokog kontrasta	Visoka razlučivost
TOČNOST	Visoka za kvantitativne razlike	Visoka za kvalitativne razlike
TROŠKOVI UPORABE	Visoki za male serije, niska za velike u odnosu na ljudski vid	Niža od umjetnih sustava za male serije
UKUPNO	Najbolje za proizvodnju u velikim serijama	Najbolje za proizvodnju u malim serijama

Budući da oko može procesirati oko 10 slika u sekundi, proizlazi da čovjek može po oku procesirati 10 000 milijuna zasebnih polja podataka. Iako su ti podatci fascinantni, današnji umjetni sustavi mogu obraditi i nekoliko bilijuna operacija po sekundi no nemaju niti približno izraženo generičko ponašanje kakvo ima ljudski vid. Zanimljivo je da su te specifikacije u biti nebitne kada se tiču ukupnih performansi sustava. I hardverska i softverska arhitektura utječe na performanse sustava, i tek udružene, te performanse diktiraju vrijeme potrebno da se izvrši cjelokupan zadatak.

Gledajući kapacitet sustava mozak-oko, trenutni umjetni sustavi su jednostavno primitivni. Raspon objekata koje mogu percipirati, brzina interpretacije i osjetljivost na svjetlosne probleme te različitosti u teksturama i reflektivnosti objekata su neki od primjera ograničenja trenutne tehnologije. S druge strane, strojni vid ima jasne prednosti kada se radi o kapacitetu rada pri visokim brzinama. Umjetni sustavi mogu vršiti razne zadatke i inspekcije u gotovo simultanom načinu na istom objektu ili na različitim objektima. Ako se dodaju višestruki senzori mogu se čak izvršavati radnje na različitim proizvodnim linijama.

Tablica 3.2 Procjena mogućnosti

MOGUĆNOSTI	UMJETNI SUSTAVI	LJUDSKI VID
UDALJENOST	Ograničene sposobnosti	Dobre kvalitativne sposobnosti
ORIJENTACIJA	Dobro za dvije dimenzije	Dobre kvalitativne sposobnosti
GIBANJE	Limitirano, osjetljivost na zamućivanje	Dobre kvalitativne sposobnosti
RUBOVI/REGIJE	Potrebna slika visokog kontrasta	Visoko razvijeno
OBLICI SLIKE	Dobro kvantitativno mjerenje	Samo kvalitativno
ORGANIZACIJA SLIKE	Ograničene sposobnosti, potreban poseban softver	Visoko razvijeno
POVRŠINSKE SJENE	Ograničene sposobnosti kod sivih tonova	Visoko razvijena skala
2D INTERPRETACIJA	Izvršna za dobro definirane parametre	Visoko razvijeno
3D INTERPRETACIJA	Vrlo ograničene mogućnosti	Visoko razvijeno
UKUPNO	Najbolje za kvantitativno mjerenje i analizu strukturirane scene	Najbolje za kvalitativnu interpretaciju kompleksnih, nestrukturiranih scena

Ljudski vid je aktivnost koja uključuje paralelno procesiranje. Sadržaj scene uzima se i pohranjuje simultano. Sa druge strane strojni vid je serijski sustav. Zbog načina funkcioniranja senzora za akviziciju slike, analiza scene se razlaže na niz serijskih operacija pri čemu dobivamo polja podataka po vremenskom trenutku.

Ljudski vid je prirodno trodimenzionalan, zbog koncepta stereovizije na kojem funkcionira. Umjetni sustavi općenito rade kao dvodimenzionalni sustavi. Dok čovjek interpretira boje bazirano na spektralnom odzivu fotoreceptora, umjetni sustavi su većinom u domeni sivih tonova neovisno o zasićenju boja i baziraju se na spektralnom odzivu senzora, a ujedno postoje brojni senzori koji omogućuju rang promatranje spektra koji je daleko iznad naših prirodnih mogućnosti. Kod ljudskog sustava vizija se bazira na interakciji sa svjetlom odbijenim od scene, dok se kod umjetnih sustava omogućava bilo koji broj i način osvjetljenja te se pojedini načini upotrebljavaju ovisno o zahtjevu aplikacije. Zaključno, jasno je da ljudski vid stvara percepciju slike i donosi zaključke na osnovu onoga što je prethodno naučeno i stavljeno u odnose, te se analize donose na osnovu prethodno naučenih modela i obrazaca kako bi se moglo reagirati u pravilnom kontekstu. U tom aspektu pred umjetnim vizijskim sustavima još je dug put.

### **3.2 Koncept izrade vizijskog sustava**

Sekvenca realizacije projekta može se definirati kako slijedi:

1. Specifikacija zadatka
2. Konstrukcija sustava
3. Izračun troškova
4. Razvoj i instalacija sustava

Uspješna konstrukcija je bazirana na detaljnim specifikacijama. Zadatak i okoliš moraju biti pomno opisani. Često se utjecaj okoliša ne definira dovoljno, kao na primjer mehaničke tolerancije, a nekada i sami zadatci. Često je uzrok toga nedostatak znanja o tim faktorima ili pretpostavka da je procesiranje i obrada slike većinom zadatak softvera te da se može lako mijenjati.

Osim specifikacija, nužno je posjedovati set uzoraka koji pokrivaju zonu dijelova koji su bez nesavršenosti kao i dijelova koji su na granici zadovoljavajućih, gotovo netočnih. Takav set uzoraka je neophodan zbog planiranja rasvjete i definiranja rezolucije kako bi se mogle razlučiti nesavršenosti. Osnovni koraci pri planiranju su:

- Izbor vrste kamere
- Određivanja vidljivog polja
- Izračun rezolucije
- Izbor leća

- Odabir modela kamere i hardverske platforme
- Odabir rasvjete
- Određivanje mehaničkih i električnih poveznica
- Osmišljavanje i odabir softvera

### **3.2.1 Definiranje vizijskog sustava**

Prvotni zadatak jest procjena zadataka i uvijeta. Opis objekta promatranja mora biti potpun kao i zahtjevi za brzinom i točnošću rada.

#### **- Dijelovi**

Potrebna je precizna definicija dijelova i cjelovit set uzoraka, kako je već napomenuto. Slijedeće karakteristike i njihov raspon trebaju biti navedeni:

- Pojedinačni uzorci ili kontinuirani
- Minimalne i maksimalne dimenzije
- Promjene oblika
- Opis specifičnosti koje trebaju biti prepoznate
- Promjene tih specifičnosti i uobičajene varijacije uzoraka
- Obrada površine
- Boja
- Korozija, uljni film i slično
- Promjene zbog rukovanja uzorkom

Ključna sposobnost vizijskih sustava je njihova sposobnost bez potrebe za fizičkom interakcijom sa predmetom rada. Promjene dijelova trebaju biti detaljno navedene. Koje se specifikacije mijenjaju i na koji način, na primjer dimenzije, oblik ili boja? Ako postoji više vrsta uzoraka, rukovanje i prepoznavanje specifičnog tipa uzorka postaje iznimno važno.

#### **- Prikaz dijelova**

Za prikaz dijelova ključni su faktori gibanje uzorka, tolerancije pozicioniranja i broj dijelova unutar scene promatranja. Ovisno o gibanju dijelova moguće su slijedeće opcije:

- Indeksirano pozicioniranje
- Kontinuirano gibanje

Za indeksirano pozicioniranje vrijeme kada se dio zaustavlja mora biti definirano jer ono utječe na vrijeme akvizicije slike. Za kontinuirano gibanje, brzina i akceleracija su ključne značajke prilikom akvizicije. Prilikom pozicioniranja



potrebno je poznavati tolerancije jer će one utjecati na polje promatranja i dubine. Ako se u sceni nalazi više od jednog uzorka potrebno je odrediti:

- Broj uzoraka u sceni
- Preklapajuće dijelove
- Dijelove koji se dodiruju

Najveća problematika uzoraka koji se preklapaju ili dodiruju jest ta da se specifičnosti uzoraka ne vide u potpunosti.


### **- Zahtjevi za performansama**

Zahtjevi za performansama se mogu promatrati kao zahtjevi za:

- Točnošću
- Vremenskim performansama.

Željena točnost mora biti definirana budući da ona utječe na potrebnu rezoluciju sustava. Često je vizijski sustav samo jedna karika u lancu proizvodnje tako da taj zadatak mora biti ostvaren unutar nekog definiranog vremena. Zahtjevi za vremenom procesiranja će utjecati na izbor platforme i hardvera i eventualno će ograničavati upotrebu pojedinih algoritama. Slijedeća vremena trebaju biti definirana:

- Vrijeme ciklusa
- Početak akvizicije
- Maksimalno vrijeme procesiranja
- Broj proizvodnih ciklusa.



Slika 3.1 Zahtjevi za procesorskim vremenom [2]

Zadnja stavka se može pokazati problematičnom ako se uzorak dostavlja pokretnom trakom i rezultat inspekcije vizijskog sustava se ne koristi odmah nego na određenoj udaljenosti (Slika 3.1).

U prvom slučaju procesiranje mora biti završeno unutar jednog ciklusa. U drugom slučaju rezultati su rezani i samo se srednje vrijeme procesiranja uspoređuje, odnosno mora biti manje od vremena ciklusa.

### ***- Informacijski protokoli***

Uobičajeno, vizijski sustav nije zaseban i neovisan sustav već koristi razna sučelja da bi komunicirao sa okolinom. Ta sučelja mogu biti namijenjena ljudima kako bi se rukovalo sustavom pomoću operatera kao što je TCP/IP, fieldbus, serijski ili digitalni I/O protokoli za komunikaciju između više uređaja. Sučelja se najčešće koriste za:

- Korišnička sučelja za rukovanje i vizualizaciju rezultata
- Definiranje trenutne vrste uzorka
- Početak inspekcije
- Definiranje rezultata
- Pohranu rezultata
- Generiranje inspekcijskih protokola za pohranu ili ispis

### ***- Prostor za instalaciju***

Za instaliranje opreme prostor instalacije je potrebno evaluirati. Treba provjeriti mogućnost prilagodbe rasvjete i instalacije kamere. Da li je pogled u scenu moguć? Koje varijacije su moguće i koja je minimalna i maksimalna udaljenost između kamere i procesorske jedinice. Nadalje ta udaljenost treba biti određena kako bi se mogla definirati potreban duljina kablova za povezivanje sustava.

### ***- Okolina***

Osim prostora, okolina mora biti provjerena kako bi se utvrdilo sljedeće:

- Ambijentalna rasvjeta
- Prljavština ili prašina od koje se treba zaštititi oprema
- Udarci ili vibracije koji utječu na opremu ili uzorke
- Utjecaj toline odnosno hladnoće
- Potreba za određenim zaštitnim razredom
- Dostupnost napajanja

### 3.2.2 Kreiranje vizijskog sustava


U ovom stadiju informacije o zadatcima, uzorcima i različitim temama o vizijskim sustavima su dostupne tako da korištenjem tih podataka možemo konstruirati vizijski sustav.

#### - Vrsta kamere

Odabir prostorne ili kamere koja skenira linijski je važna odluka koja slijedi u ovoj fazi konstrukcije vizijskog sustava jer utječe na izbor hardvera i način akvizicije slike.

Prostorne kamere su uobičajene u automatizaciji i nude prednosti u usporedbi sa linijskim skenerom. Postavljanje takve kamere većinom je lakše budući da pomicanje uzoraka ili kamere nije potrebno. Podešavanje linijskog skenera u okolišu bez kretanja može biti zahtjevan zadatak. Isto tako trigeriranje linijskog skenera zahtjeva posebnu pažnju.

No unatoč tome korištenje linijskih skenera nudi više rezolucije u smjeru skeniranja i popečnom smjeru (Slika 3.2) gdje je rezolucija definirana brzinom skeniranja. Takav način rada omogućuje linijskim skenerima da procesiraju kontinuiran niz slika i podataka u suprotnosti sa konvencionalnim kamerama gdje se pojedina slika snima i obrađuje zasebno.




Slika 3.2 Smjerovi skeniranja linijskog skenera

Na osnovu navedenog moguć je odabir između klasične kamere ili linijskog skenera. Izračun rezolucije kamere je potreban u ovom koraku kako bi se utvrdila dostatna vrijednost za izvršavanje zadatka. Nakon toga potrebno je izabrati i model kamere.

### **- Pokrivenost scene**

Područje gledanja odnosno pokrivenost scene se određuje na osnovu slijedećih faktora:

- Maksimalna veličina promatranih uzoraka
- Maksimalna varijacija prikaza dijelova tijekom translacije i orijentacije
- Margina definirana kao odstupanje veličine uzorka
- Mjerilo odnosno faktor povećanja senzora kamere



Slika 3.3 Pokrivenost scene [2]

Kao što je vidljivo na slici (Slika 3.3), crni uzorak označen sa brojem 1 predstavlja maksimalnu veličinu uzorka. Zbog pozicioniranja uzorak može preći maksimalnu varijaciju u veličini kao što se vidi na sivom uzorku označenim sa brojem 2. Veličina scene označena sa brojem 3 vodi do veličine koja je definirana maksimalnom veličinom uzorka plus maksimalna tolerancija pozicioniranja. Polje označeno brojem 4 je definirano dodatnom potrebom za marginom između

uzorka i slike. Za procesiranje slike možda će biti potrebno osigurati prostor između uzorka i rubova slike. Nadalje za održavanje i instaliranje kamere prikladno je omogućiti određene tolerancije prilikom pozicioniranja.

Zona označena brojem 4 je željena pokrivenost scene no izračunata veličina slike se treba prilagoditi u odnosu na rezoluciju senzora kamere. Većina dostupnih kamera ima omjer veličine stranica slike koji iznosi 4:3. Stoga se za svaki smjer u zoni pogleda (FOV, *field of view*) veličina računa izrazom:

$$FOV = \text{maksimalna veličina uzorka} + \text{tolerancije pozicioniranja} + \text{margine} + \text{adaptacija omjeru veličine stranica senzora}$$

### **- Rezolucija**

Kada se govori o rezoluciji neophodno je razlikovati slijedeće:

- Rezolucija senzora kamere
- Prostorna rezolucija
- Točnost mjerenja

*Rezolucija senzora kamere* predstavlja broj redaka i stupaca koji kamera ima, a definiran je građom optičkog senzora. Ta veličina se mjeri u pikselima. Osim te veličine veličina jednog piksela odnosno čelije je podatak neophodan za odabir odgovarajuće optike.

*Prostorna rezolucija* je usko vezana uz mapiranje objekata stvarnog svijeta na senzor koji formira sliku. Prostorna rezolucija se može mjeriti u mm/pikselu. Ova rezolucija je ovisna o senzoru kamere i veličini polja pogleda. Bitno je napomenuti da neke kamere ne posjeduju kvadratične piksele tako da je rezultirajuća prostorna rezolucija različita u horizontalnom i vertikalnom smjeru.

*Točnost mjerenja* predstavlja općenite performanse sustava – najmanja značajka koju je moguće mjeriti. Ovisno o algoritmima mjerna rezolucija može se razlikovati od prostorne rezolucije.

Kod procesiranja slike kontrast značajki kao i softverski algoritmi određuju hoće li značajka biti mjerljiva. Ako je kontrast sitnih nesavršenosti loš, softver možda neće biti u mogućnosti detektirati nesavršenost veličine jednog piksela već će možda biti potrebno četiri ili pet piksela kako bi se detektirala ta značajka. S druge strane, algoritmi kao što su pronalaženje kružnice ili subpikseliranje dozvoljavaju veće točnosti mjerenja nego što je prostorna rezolucija.

Kao što je vidljivo (Tablica 3.3), možemo pretpostaviti točnost nekih algoritama iako te vrijednosti ne treba uzeti zdravo za gotovo stoga što su ovisne o upotrijebljenim algoritmima i kvaliteti same slike.

Tablica 3.3 Očekivana točnost u ovisnosti o algoritmu

<b>Algoritam</b>	<b>Točnost u pikselima</b>
Detekcija rubova	1 / 3
Blob	3
Pronalaženje obrazaca	1

Dolazi se do zaključka da je prostorna rezolucija koja je potrebna da bi se postigla željena mjerna točnost ovisna o kontratu značajki i softverskim algoritmima.

Kako bi se odabrao pravilan model kamere, kao što je navedeno, potrebno je odrediti željenu rezoluciju stoga veličina najmanje značajke mora biti proučena jer je broj piksela koji opisuju tu značajku od iznimne važnosti (Tablica 3.4). Procjena prostorne rezolucije se računa kako slijedi:

$$R_s = FOV / R_c \quad (3.1)$$

$$R_c = FOV / R_s \quad (3.2)$$

Tablica 3.4 Popis varijabli za izračun rezolucije

<b>Naziv</b>	<b>Varijabla</b>	<b>Mjerna jedinica</b>
Rezolucija kamere	$R_c$	piksel
Prostorna rezolucija	$R_s$	mm/piksel
Područje pogleda	FOV	mm
Veličina najmanje značajke	$S_f$	mm
Broj piksela najmanje značajke	$N_f$	piksel

Neophodna prostorna rezolucija može se izračunati prema slijedećem izrazu:

$$R_s = \frac{S_f}{N_f} \quad (3.3)$$

Ako je područje pogleda poznato rezolucija kamere može se izračunati prema izrazu:

$$R_c = \frac{FOV}{R_s} = FOV \cdot \frac{N_f}{S_f} \quad (3.4)$$

Navedeni izračun mora biti proveden za horizontalni i za vertikalni smjer. Za klasičnu kameru to je prilično jednostavan zadatak no treba uzeti u obzir omjer stranica senzora kamere.

### **- Odabir kamere, frame grabbera i hardverske platforme**

U ovom stadiju poznate su rezolucija kamere i način skeniranja radnog područja tako da je moguće odabrati adekvatni model kamere. Odabir kamere, frame grabbera i hardverske platforme je zadatak koji je povezan i izvodi se u jednom koraku.

*Model kamere* – Nakon što je odabran odgovarajući model treba pripaziti na slijedeće stavke i da li su potrebne:

- Senzor u boji
- Tehnologija sučelja
- Progresivni sken
- Veličina
- Cijena i dobavljaljivost

*Frame grabber* – Model kamere utječe na odabir frame grabbera i obrnuto, bitno je da su sučelja kamere i frame grabbera kompatibilni. Treba razmotriti slijedeće stavke:

- Kompatibilnost sa brzinom prijenosa piksela
- Kompatibilnost sa softverskom bazom
- Broj kamera koje se mogu adresirati
- Algoritmi kontrole kamere putem frame grabbera
- Tajming i trigeriranje kamere
- Dostupnost procesiranja na samoj platformi
- Dostupnost standardnih I/O konekcija
- Cijena i dostupnost

*Brzina prijenosa piksela* – Brzina akvizicija slike u smislu broja piksela po sekundi (Tablica 3.5). Brzina prijenosa piksela može se izračunati kako slijedi:

$$PR = R_{c_{hor}} \cdot R_{c_{ver}} \cdot fr + overhead \quad (3.5)$$

Tablica 3.5 Varijable brzine prijenosa piksela

Naziv	Varijabla	Mjerna jedinica
Brzina prijenosa piksela	$PR$	piksel/s
Horizontalna rezolucija kamere	$Rc_{hor}$	piksel
Vertikalna rezolucija kamere	$Rc_{ver}$	piksel
Broj slika	$fr$	Hz
Rezolucija kamere	$Rc$	piksel

Dodatak od 10% do 20% je potreban zbog uskog grla koje se može pojaviti na sučelju. Bzinu prijenosa piksela odrađuju kamera frame grabber i platforma za procesiranje. Za frame grabber i računalo suma svih brzina i prijenosa piksela je od ključne važnosti. Kao vodilja mogu poslužiti podatci o propusnosti pojedinih protokola (Tablica 3.6).

Tablica 3.6 Brzina prijenosa podataka različitim sučeljima

Tehnologija sabirnice	Maksimalna propusnost – MB/s
PCI	96
PCI– Express	250 po liniji (moguće je kombinirati linije)
IEEE 1394	32
CameraLink	max 680 za full frame CameraLink

**Hardverska platforma** – U domeni hardverskih platformi postoji mogućnost odabira između smart kamera, kompaktnih vizijskih sustava ili PC baziranih sustava. Troškovi i performanse značajno variraju među sustavima.

Potrebno je provjeriti kompatibilnost sa frame grabberom. U domeni operativnog sustava potrebno je da softverska baza bude podržana. Treba odlučiti da li je potreban sustav koji će raditi u stvarnom vremenu jer se onda može govoriti o visoko brzinskim aplikacijama.

Hardverska platforma mora biti u mogućnosti rukovati sa željenom brzinom prijenosa piksela i procesorskim opterećenjem. Za sustave sa više kamera ili sustave koji rade pri visokim brzinama kompaktni vizijski sustavi mogu biti ograničavajući.




### - Odabir optike

Nakon što su definirani područje pogleda i rezolucija kamere potrebno je odabrati odgovarajuće leće za kameru. Vrlo važan parametar je udaljenost leće od kamere odnosno veličina adaptera. Korištenjem veće udaljenosti ćemo općenito povećati kvalitetu slike. Ta udaljenost je potrebna kako bi se izračunala žarišna udaljenost.

*Žarišna udaljenost* – Bazirano na izrazima za tanke leće može se odrediti žarišna udaljenost. Iako ti izrazi nisu točni kada se radi o debelim lećama koje se koriste sa kamerama dobiveni rezultati ipak omogućuju dobar odabir žarišne udaljenosti. Da bismo dobili žarišnu udaljenost potrebni su duljina adaptera i povećanje objektiva. Standardni objektivi su dostupni sa žarišnim duljinama od 8 mm, 16 mm, 25 mm, 35 mm, 50 mm ili veće.

*Promjer objektiva i veličina senzora* – Veličine senzora variraju, kategorizirani su u veličine od 1/3", 1/2", 2/3" te 1". Dane veličine nisu točna dimenzija već veličina koja govori da određeni senzor leži unutar kružnice navedenog promjera.

Uz specifikacije objektiva navodi se i maksimalna veličina senzora koje prihvaćaju. Izbor leća i kamere mora biti odgovarajući (Slika 3.4). Korištenjem 1" senzora sa 2/3" objektivom rezultirat će u loše osvijetljenom senzoru jer će slaba osvijetljenost i aberacije predstavljati velike probleme.



Slika 3.4 Područja osvijetljena objektivom i kamerom [2]

Za kamere više rezolucije zahtjevi za optikom su veći nego kod kamere niže rezolucije. Korištenje jeftine optike može dovesti do slike loše kvalitete iako se koristi senzor visoke rezolucije.

### - Odabir rasvjete


Osvjetljenje u vizijskim sustavima je individualna selekcija optimalnog koncepta. Pronalazak najboljeg rješenja je rezultat eksperimentiranja na osnovu teorijskog pristupa.

Odabir rasvjete određuje kvalitetu pojavljivanja značajki na slici. Značajke na slici moraju biti predstavljene maksimalnim kontrastom. Izazov planiranja rasvjete je kako povećati omjer signal-šum te naglasiti značajke kako bi se maksimizirao kontrast. Svako poboljšanje u domeni rasvjete će povećati performanse vizijskog sustava i pouzdanost. U isto vrijeme smanjit će se kompleksnost softvera i algoritama. Kontrast se može povećati slijedećim pristupima:

- Ključni faktor je smjer svjetlosti. Može dolaziti iz svih smjerova raspršena ili biti usmjerena iz raznih mjesta.
- Spektr svjetlosti također utječe na kontrast. Ne treba zanemariti niti ultraljubičasto ili infracrveno zračenje kao i optičke filtere. Za aplikacije u boji treba provjeriti korisnost spektra jer, na primjer, LED rasvjeta uobičajeno ne osigurava homogeni spektar.
- Efekt polarizacije povećava kontrast između područja objekata koja izravno reflektiraju svjetlost u usporedbi sa difuznom refleksijom. Polarizacija će istaknuti značajke površini kao što su metal ili staklo.

Najčešće postavke rasvjete vizijskih sustava su (Slika 3.5):

- Stražnje osvjetljenje
- Prednje osvjetljenje




Slika 3.5 Prikaz prednjeg (a) i stražnjeg (b) osvjetljenja

*Stražnje osvjetljenje* – Obično se izvodi kao panel koji svjetli i na kojega se stavlja predmet rada (Slika 3.5 - c). Najuobičajeniji izvor svjetlosti za taj tip rasvjete su LED diode i fluorescentne cijevi. Pozadinsko osvjetljenje može biti i difuzno tako da omogućava dolazak svjetlosti iz različitih smjerova.

Jedna od metoda rasvjete je i kondenzirajuća rasvjeta. Koriste se posebne leće kako bi se pozadinsko osvjetljenje fokusiralo u smjeru kamere. Takvo osvjetljenje omogućava telecentričnu putanju zraka svjetlosti pa se stoga koristi u sustavima koji su namijenjeni mjerenju.

*Prednje osvjetljenje* – Moguće je navesti niz tehnika (Slika 3.6). Neke od njih su:

- Usmjerena svjetlost (a) – Svjetlost dolazi iz određenih smjerova: to mogu biti prstenasti ili linijski oblici.
- Difuzna svjetlost (b) – Svjetlost dolazi iz svih smjerova. Najčešća je izvedba sa kapicom unutar koje se nalazi prsten LED dioda
- Konfokalna svjetlost (f) – Optika lomi svjetlost i usmjerava je tako da svjetlost dolazi iz smjera optičke osi kamere.
- Svjetlo polje (d)– Varijacija usmjerene svjetlosti. Svjetlost je usmjerena tako da je reflektirana od površine predmeta u kameru. Na taj način površina predmeta na slici ispada svjetlija, a dijelovi koji ne reflektiraju ispadaju tamni.



Slika 3.6 Ilustracija različitih postavki rasvjete [3]

- Tamno polje (e) – Varijacija usmjerene svjetlosti gdje se reflektirano svjetlo usmjerava od kamere pri čemu površina predmeta ispada tamna, a ostali dijelovi ispadaju svjetliji.

Uobičajeni izvori svjetlosti koji se primjenjuju u vizijskim sustavima su:

- Fluorescentne cijevi – Dostupne su u formi prstena ili ravne cijevi. Za primjenu u strojnoj viziji važne su visokofrekventne aplikacije rasvjete. Ako se ovaj tip rasvjete koristi sa standardnim napajanjem na 50 Hz intenzitet oscilacija svjetlosti će biti vidljiv na slikama.
- Halogena i xenon rasvjeta – Ova rasvjeta se napaja istosmjernom strujom tako da oscilacije svjetlosti nisu problem. Halogena rasvjeta se najčešće upotrebljava u kombinaciji sa staklenim vlaknima, dok se xenon rasvjeta koristi u aplikacijama koje zahtijevaju blic.
- LED rasvjeta – Prednosti LED rasvjete su korištenje istosmjerne struje, dug životni vijek koji nadmašuje ostale vrste izvora svjetlosti. Zbog veličine dolaze u malim pakiranjima i većinom ne zahtijevaju zaseban dodatni hardver.
- Laser – Laserska svjetlost se koristi za specijalne aplikacije kao što je triangulacija.

Za nalaženje optimalnog rješenja odnosno postavki, potrebno je načiniti bazni model. Korištenje kamere u tom koraku nije potrebno jer se ljudski vid može upotrijebiti da odradi tu zadaću. Za pojedine postavke potrebno je načiniti zapise kako bi se mogli usporediti parametri pojedinih postavki i odabrati najbolja.

### **- Mehanička konstrukcija**

Nako što se odredi tip kamere, optika, adapteri i rasvjeta mogu se definirati mehanički parametri vizijskog sustava. Prilikom montaže kamera i rasvjete bitno je omogućiti naknadna podešavanja istih radi prilagodbe ili održavanja. Uređaji moraju biti zaštićeni od udaraca i vibracija, ponekad je neophodna mehanička izolacija i stabilizacija elemenata.

Položaj kamere i rasvjete mora se moći lako podešavati. Ipak, nakon podešavanja kamera i rasvjeta se ne smiju moći lako maknuti iz definiranog položaja. Potrebno je omogućiti takav ustroj da se podešavanje vrši unutar potrebnog raspona i da se ključni stupnjevi slobode gibanja podešavaju neovisno.

## **- Električna konstrukcija**

Najophodnije je prvo definirati potrebno napajanje vizijskog sustava. Ako se zahtjeva poseban razred zaštite treba odabrati prikladnu kameru rasvjetu i ostale komponente. Potrebno je odrediti potrebnu dužinu svih kablova, budući da ovisno o sučeljima i protokolima pojedini kablovi su određene maksimalne duljine te treba razmotriti korištenje pojačivača signala ili korištenje optičkih kablova kako bi se dosegle veće udaljenosti.

## **- Softver**

U ovom stadiju potrebno je načiniti dva koraka:

- Odabir softverske baze
- Odabir, izrada i implementacija specifičnog softvera

Kada se odabire softver potrebno je pažnju posvetiti funkcionalnosti. Bitno je odabrati osnovni koncept glavnih algoritama. Ne treba posebno napominjati da softver treba biti kompatibilan sa hardverom za akviziciju i obradu slike.

Često se zajedno sa vizijskim sustavima prodaju i softverski paketi. Takva koncepcija značajno olakšava izradu aplikacija budući se mogu koristiti gotovi alati ali za kompleksne zadatke često osnovni alati neće biti dostatni. Rješenje je softver koji ima konfigurabilne algoritme koji se mogu potpuno prilagoditi potrebama vizijskog sustava. U tom slučaju integracija je kompleksna jer je u postupak uključeno više programiranja zbog toga što je potrebno programirati cijelu softversku strukturu.

Softverska struktura i algoritmi koji se koriste u vizijskom sustavu su iznimno ovisni o zadatku koji sustav treba obavljati stoga ne postoje općenite smjernice. Ipak, za većinu aplikacija softver za procesiranje slijedi neke rutine:

- Akvizicija slike
- Pretprocesiranje
- Lokalizacija značajki
- Ekstraktiranje značajki
- Interpretacija značajki
- Generiranje rezultata
- Sučelje za manipulaciju

Sekvenca rada vizijskog sustava započinje akvizicijom slike. Pri tome treba zadovoljiti kriterije kao što su okidanje slike ili blica. Nakon što su slike snimljene postoji moguća potreba za pretprocesiranjem. Najčešće se radi o korištenju filtera ili zasjenjenju. Ti koraci mogu se izvesti ovisno o aplikaciji, hardverski ili softverski.

Pretprocesiranje često uzima puno procesorskog vremena i treba se koristiti samo ako je neophodno.

Zbog tolerancija prilikom pozicioniranja položaj značajki treba lokalizirati. Ovisno o njihovom položaju mogu se definirati regije interesa. Tako definiran postupak omogućuje da se procesiraju samo dijelovi slike koji su unutar regije interesa umjesto cijele slike, te se time štedi vrijeme procesiranja.

Ekstraktiranje značajki koristi osnovne algoritme kako bi se prepoznale značajke. Osnovni algoritmi su analiza blobova, analiza teksture, određivanje uzoraka ili detektiranje rubova. Interpretacija značajki u osnovi izvodi vizijski zadatak, mjerenje, verifikaciju ili čitanje koda.

Generiranje rezultata je slijedeći korak. Ovisno o značajkama i njihovoj interpretaciji rezultat se može uspoređivati sa tolerancijama odnosno uzorak se može proglasiti dobrim ili lošim.

Softver treba omogućiti jednostavno rukovanje vizijskim sustavom:

- Vizualizacija stvarnih slika sa svih kamera
- Mogućnost snimanja slika
- Softver treba omogućiti lako rukovanje održavanje i kalibraciju sustava
- Mogućnost spremanja statističkih podataka sustava kako bi se mogla pratiti pouzdanost sustava
- Detaljna vizualizacija procesiranja slike kako bi se mogli pratiti uzroci eventualnih ispada sustava
- Ključni parametri procesiranja moraju biti lako dostupni zbog adaptacije sustava

### **3.2.3 Troškovi**

Prije početka izvršavanja projekta potrebno je procijeniti troškove. Oni mogu biti podjeljeni u inicijalne troškove razvoja i troškove korištenja sustava. Troškovi razvoja sastoje se od:

- Projekt menadžmenta
- Osnovnog dizajna
- Hardverskih komponenti
- Softverskih licenci
- Razvoja softvera
- Instalacije
- Probni rad, test isplativosti
- Obuke
- Dokumentacije

Ako postoji potreba za nekoliko istih sustava, troškovi slijedećih sustava će biti manji za iznos razvoja prototipa.

Kada se spominju operativni troškovi treba razmotriti slijedeće:

- Održavanje
- Izmjena opreme (rasvjeta)
- Potrošni materijal i mediji (struja, komprimirani zrak)
- Troškovi adaptacije sustava zbog promjene proizvoda

Od ostalih čimbenika koje se neće detaljno objašnjavati treba spomenuti:

- Realizaciju projekta
- Razvoji i instalaciju
- Obuka
- Dokumentacija

## 4. OSNOVE OBRADJE I AKVIZICIJE SLIKE

Tehnologija vizijskih sustava uključuje rad sa mnogo vizualnih varijabli. U većini slučajeva te varijable su međusobno povezane i utječu jedne na druge. Računalna vizija je dugo vremena bila promatrana kao specifično računalna znanost koja se bavi samo matematičkim modelima i procesiranjem slike dok su se izvori i nastajanje te iste slike zanemarivali.

Taj pristup se promjenio i sada se cijela grana znanosti o vizijskim sustavima promatra kao holistički model sustava koji su povezani. Takav pogled ima dvije izravne posljedice, prvi je taj da dobro konstruiran sustav može kompenzirati gubitke u drugim poljima, primjerice kvalitetna optika uklanja potrebu za naknadnim algoritmima poboljšavanja slike, i drugi koji kaže da proces akvizicije slike postaje dinamički i adaptivan proces. Cijela znanost teži razvijanju sustava znanih kao aktivna vizija.

### 4.1 Obrada slike

Područje koje se bavi digitalnom obradom slike odnosi se na obradu digitalnih slika pomoću neke vrste računala. Slike se mogu obrađivati na računalu iz više razloga. Postoje dvije osnovne različite svrhe zbog koji se koristi računalna obrada. Prva je poboljšavanje vizualne kvalitete prikaza slike korisniku kao što je čovjek. Druga je priprema slike za analizu dimenzija i utvrđivanje karakteristika i strukture na samoj slici. Tehnike koje se koriste za ove radnje nisu uvijek iste no postoji veliko preklapanje u području uporabe u bilo kojoj od navedenih domena.

Tablica 4.1 Klasifikacija obrade slike

	ULAZ	IZLAZ
OBRADA SLIKE	Slika	Slika
ANALIZA SLIKE	Slika	Dimenzije / Karakteristike
RAZUMIJEVANJE SLIKE	Slika	Opis slike na visokom nivou




Obrada slike se može podijeliti po nivoima:

- Niži nivo obrade
- Srednji nivo obrade
- Viši nivo obrade

*Niži nivo obrade* uključuje primitivne operacije gdje su ulaz i izlaz iz sustava slike. Glavna funkcija je predobrada slike kao što su smanjenja šumova, poboljšavanje kontrasta, izoštravanja i slično

*Srednji nivo obrade* uključuje računalni vid i prepoznavanje obrazaca. Ulaz u sustav je slika, a izlaz iz sustava su svojstva slike kao što su npr. rubovi. Glavne funkcije su segmentacija, klasifikacija/prepoznavanje objekata.

*Viši nivo obrade* slike uključuje algoritme koji daju smislene informacije o nizu prepoznatih objekata. Prilikom obrade se izvršavaju kognitivne funkcije koje se inače povezuju sa ljudskim vidom.



Slika 4.1 Nivoi obrade slike

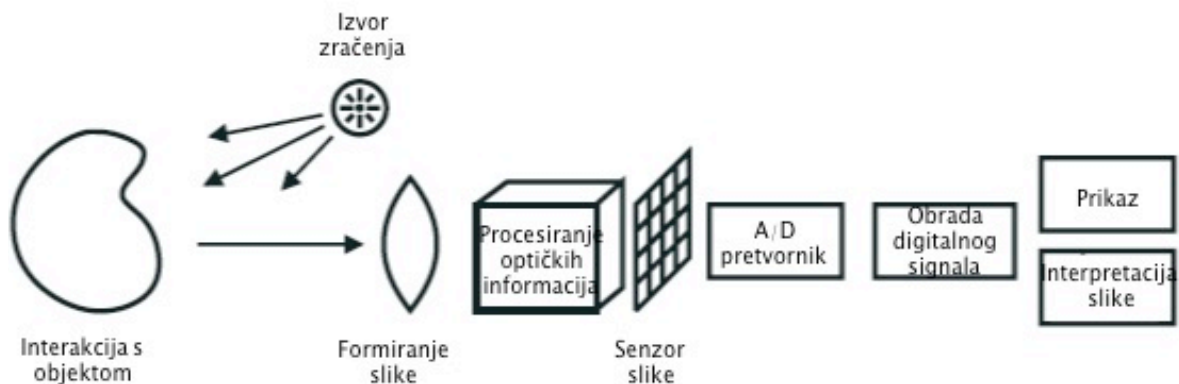
## 4.2 Akvizicija slike

Kao što je već spomenuto prvi korak u akviziciji slike je formacija slike. Slike se mogu stvoriti raznim tehnologijama. Većina sustava konvertira reflektiranu svjetlost u električni signal koji se onda digitalizira. Neki sustavi koriste elektromagnetska zračenja koja su izvan vidljivog dijela spektra, kao što su X zrake, laserska svjetlost, ultrazvuk ili infracrveno zračenje. Konačni rezultat je većinom skup uzoraka u određenom energetsom obliku.

Potrebni čimbenici za akviziciju slike su:

- Izvor zračenja
- Kamera
- Senzor
- A/D pretvarač
- Jedinica za obradu podataka

Akvizicija slike se odvija na način da izvor svjetla emitira neku vrstu zračenja. Izvor zračenja nam je potreban u slučaju da predmet koji promatramo nije osvijetljen ili ako predmet ne odašilje neku vrstu zračenja. Kada postoje ti uvjeti kamera ne može ništa uočiti. Zbog toga je izvor neke vrste zračenja od ključnog značenja za stvaranje slike. Kamera skuplja zračenje emitirano od objekta te tako određuje ishodište zračenja u prostoru. Slijedi formiranje slike u kameri. Senzori i analogno digitalni pretvornik pretvaraju dobivenu gustoću toka zračenja u signal koji je prikladan za daljnju obradu, odnosno razumijevanje dobivenih informacija. Signal dolazi u jedinicu za obradu digitalnog signala te se iz njega izvlače korisne informacije o obilježjima predmeta kojeg gledamo kako bismo mogli odrediti njegova svojstva kao što su tekstura, veličina, udaljenost i slično (Slika 4.2). Nakon toga slika je spremna za prikaz ili daljnju obradu. Primjer daljnje obrade bi bilo praćenje objekta sustavom vizijske navigacije.



Slika 4.2 Lanac elemenata u procesu akvizicije slike [3]

### 4.3 Parametri stvaranja slike


Do formiranja slike dolazi kada senzor detektira zračenje koje je bilo u interakciji sa fizičkim objektima (Slika 4.3). Prilikom stvaranja slike postoji veiki broj parametara koji utječu na konačni izgled slike.

*Optički parametri* leće karakteriziraju optičke senzore, a ovise o:

- Vrsti leće
- Žarišnoj duljini
- Polju pogleda
- Promjeru leće

*Fotometrički parametri* pojavljuju se u modelima gdje svjetlosna energija dolazi do senzora nakon što je reflektirana od predmeta iz scene. Fotometrički parametri uključuju:

- Tip svjetlosti
- Smjer
- Intenzitet rasvjete
- Reflektirajuća svojstva površina unutar scene
- Utjecaj strukture senzora na primljenu količinu svjetlosti.



Slika 4.3 Prikaz stvaranja slike

Na dobivenu sliku uvelike utječe vrsta senzora za stvaranje slike. Senzori se mogu kategorizirati prema osjetljivosti. Elektromagnetski senzori su osjetljivi na određeni raspon elektromagnetskog zračenja koje se dijeli na:


- Gama zračenje
- Rendgensko zračenje
- Ultraljubičasto zračenje
- Vidljivo zračenje
- Infracrveno zračenje
- Mikrovalno zračenje.

#### 4.4 Senzor slike

Senzor slike je uređaj koji konvertira primljeno elektromagnetsko zračenje u električni signal (Slika 4.4). Najčešće se koristi u digitalnim kamerama i raznim vizijskim uređajima. Senzori slike mogu biti različitog ustroja i građe, kao i podvrsta, no danse se najčešće koriste dva tipa senzora:


- CCD senzor
- CMOS senzor.

CCD predstavlja skraćeni naziv koji u originalu znači *charge-coupled device*, Dok kratica CMOS znači *complementary metal-oxide-semiconductor*.



Slika 4.4 Građa senzora slike


Kada svjetlost padne na senzor započinje serijsko očitavanje svakog pojedinog piksela. Sa svakog piksela signal se prenosi u pojačalo koje obađuje signal s jednog reda piksela na senzoru. Nakon toga se informacije brišu, a njihovo mjesto zauzima slijedeći red piksela. Taj proces se ponavlja sve dok se ne obradi svaki red sa senzora i tek tada je senzor spreman za ponovno osvjetljavanje. Bez obzira što taj proces traje kratko, ipak je potrebno neko određeno vrijeme. O tome ovisi brzina samog sustava za akviziciju slike, odnosno koliko slika senzor može snimiti u sekundi (Slika 4.5).



Slika 4.5 Rad senzora slike

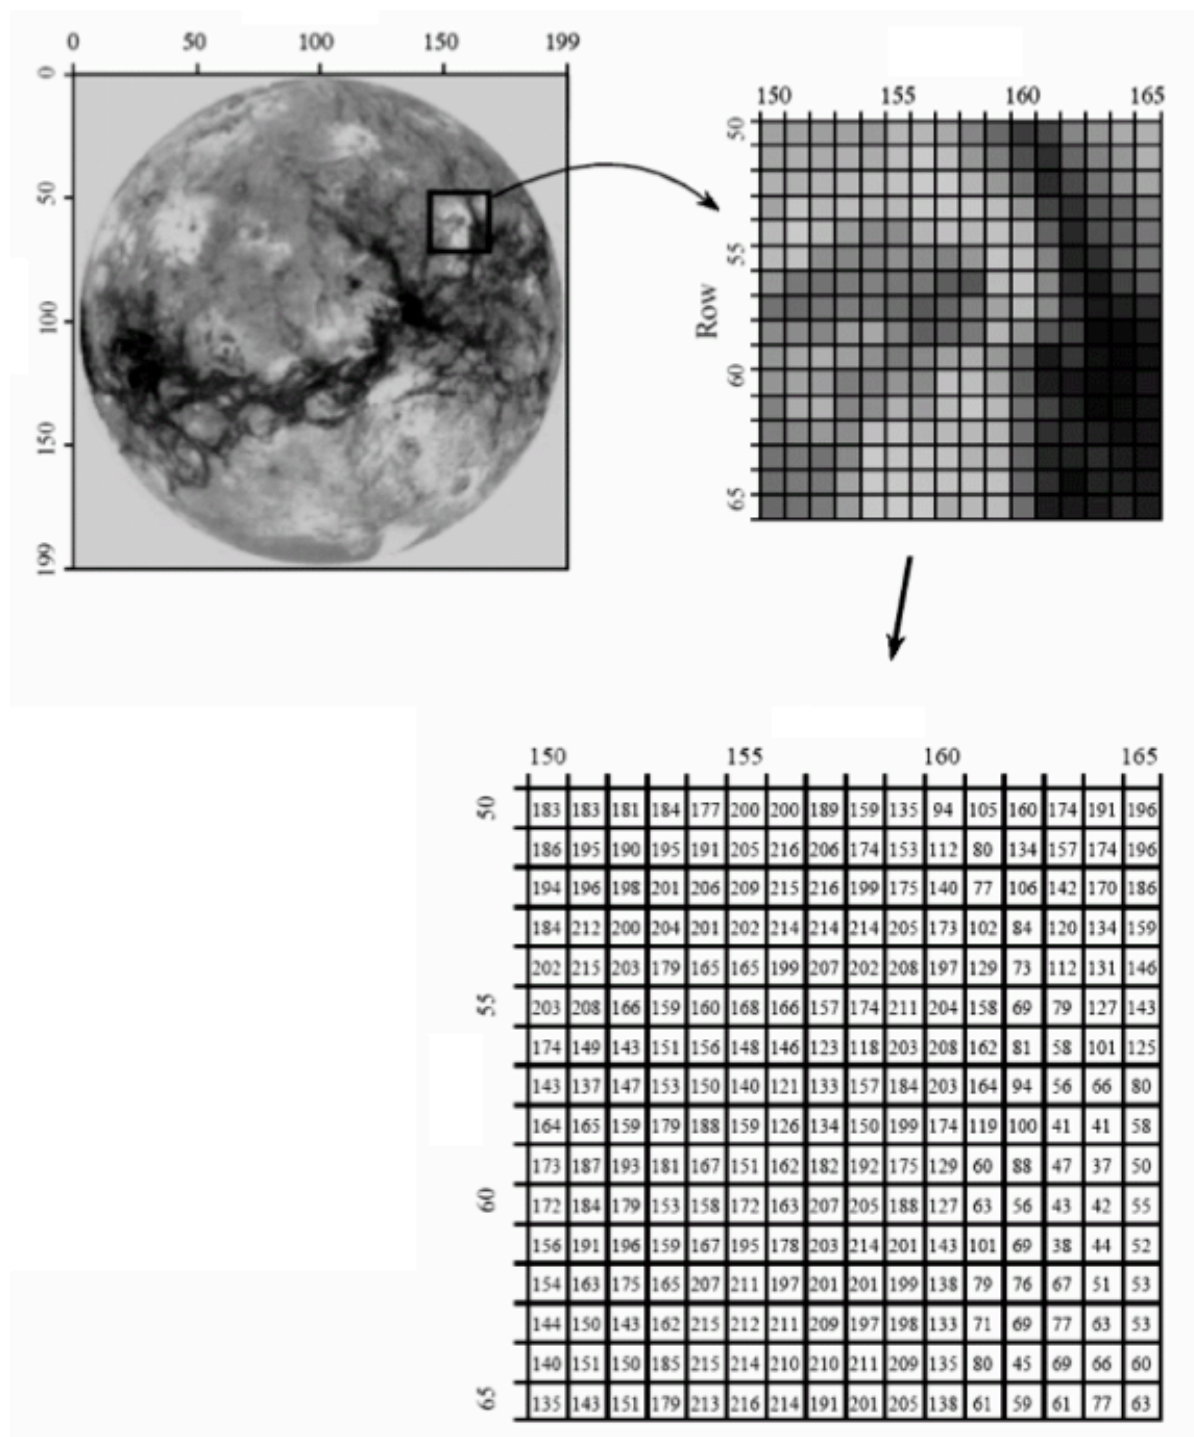
## 4.5 Slika

Slika nastaje u kameri i predstavlja ulazni podatak za vizijski sustav. Digitalna slika je zapravo zapis digitalnih brojeva u dvodimenzionalnoj matrici koji reprezentira dvodimenzionalnu sliku u stvarnosti. Stvarna slika se dijeli u male regije nazvane elementima slike ili poznatije, pikselima. Matrica se sastoji od  $x$  stupaca i  $y$  redaka, koji predstavljaju površinske koordinate slike, odnosno piksele, a vrijednosti elemenata matrice  $f(x, y)$  proporcionalne su intenzitetu osvjetljenja pripadajućih točaka iz scene. Te vrijednosti se obično formiraju na izlazu senzora kamere. Rezolucija slike definirana je brojem stupaca i redaka ( $x, y$ ), odnosno njihovim umnoškom koji predstavlja ukupan broj piksela.



Slika 4.6 Pikseli sadržani u slici

U proces pretvorbe iz stvarne slike u digitalnu sliku na mjestu svakog piksela mjeri se svjetlina stvarne slike i pretvara u cijeli broj. Svaki element (piksel) je  $m$  – bitni broj koji definira koliko razina intenziteta osvjetljenja svaki piksel može poprimiti. Koristeći  $m$  bitova dobivamo  $2^m$  vrijednosti u rasponu od 0 do  $2^m - 1$ . Slike se mogu podijeliti na crno-bijele i slike u boji. Crno-bijele slike se dalje mogu podijeliti na monokromatske i slike u nijansama sive boje. Razlika između monokromatske slike i slike u nijansama sive boje je u broju bitova koji se koriste za zapisivanje. Kod monokromatske slike piksel može biti crn ili bijel, tako da je za zapisivanje potreban 1 bit. Kod slike u nijansama sive boje piksel može biti crn, bijel ili siv u rasponu od 256 nijansi, tako da je za zapisivanje potrebno 8 bitova (Slika 4.6).




Slika 4.7 Matrica slike i pripadajuća slika [4]



## 4.6 Analiza slike

Analiza slike je proces kojim se iz slike dobivaju informacije (Slika 4.8). Glavna karakteristika je da je ulaz u sustav samo slika.



Slika 4.8 Osnova procesa analize slike

Analiza i interpretacija podrazumijevaju otkrivanje, identifikaciju i razumijevanje uzoraka koji su od interesa. Automatska analiza slike mora biti u mogućnosti pokazati određeni nivo inteligencije. Stoga se očekuje:

- Mogućnost izdvajanja značajnih informacija iz mase irelevantnih detalja
- Mogućnost učenja na osnovu uzoraka i generalizacije naučenog tako da se može primijeniti u novim, drugačijim okolnostima
- Sposobnost zaključivanja iz nekompletnih informacija.


Sustavi za prepoznavanje pronalaze objekte iz stvarnog svijeta tako da analiziraju sliku prizora koristeći modele objekta uz pomoć kojih vrše usporedbu. Prepoznavanje je sposobnost sustava da na temelju dobivenih informacija identificira zadane objekte ili njihove značajke, koje su mu preddefinirane. Značajke u vizijskim sustavima mogu biti oblici, boje, teksture i slična obilježja. Prepoznavanje nije moguće bez prethodnog znanja, bilo ono naučeno ili zadano. Proces prepoznavanja započinje od detektora značajki koji primjenjuje različite operatore na slike te pomoću njih pronalazi i formira hipoteze. Korištene značajke ovise o karakteristikama objekata koje sustav treba prepoznati te o organizaciji baze modela za vjerojatnost u slučaju da odgovaraju referentnom modelu.

Baza modela za prepoznavanje koristi sheme za indeksiranje u svrhu verifikacije hipoteze u kojoj se donosi odluka o prihvatanju ili odbijanju kandidata, odnosno prihvaća se kandidat sa najvećim brojem značajki. Sustavi za prepoznavanje koriste se sa ciljem dobivanja geometrijskih transformacija traženog predmeta, rotacije, translacije i skaliranja.



#### 4.6.1 Detekcija rubova

Detekcija rubova je algoritam koji nalazi rubove duž linije piksela na slici. Ovaj alat se koristi kako bi se identificirali i locirali diskontinuiteti u intenzitetu piksela na slici (Slika 4.9). Diskontinuitet se najčešće manifestira sa naglim promjenama u intenzitetu piksela koji karakteriziraju granice objekata na sceni. Detekcija rubova je efektivan alat za mnoge aplikacije računalne vizije. Koristi se za mjerenje, detekciju i prilagodbu na objektima.




Slika 4.9 Primjer detekcije rubova [5]

Rub je značajna promjena u vrijedostima sivih tonova između susjednih piksela na slici. Regije pretraživanja mogu poprimiti formu linije, kružnice, elipse, pravokutnika ili nekog drugog oblika. Algoritam analizira vrijednosti piksela duž profila kako bi detektirao značajne promjene vrijednosti piksela koje se definiraju kao rub. Najvažniji parametri pri detekciji rubova su (Slika 4.10):

- Intenzitet ruba – Definira minimalnu razliku u vrijednostima sivih tonova između pozadine i slike. Intenzitet ruba može varirati iz razloga kao što su uvjeti osvjetljenja ili zbog objekata koji imaju različite karakteristike prikaza u sivom spektru.
- Duljina ruba – Definira maksimalnu udaljenost na kojoj se mora dogoditi razlika u sivim tonovima između ruba i pozadine.
- Polaritet ruba – Definira da li rub raste ili pada. Rastući rub karakterizira porast vrijednosti sivih tonova kako se prelazi preko ruba. Padajući rub karakterizira pad vrijednosti sivih tonova kako se prelazi preko ruba.

- Položaj ruba – Lokacije x, y na slici predstavljaju položaj ruba




Slika 4.10 Model ruba [6]

#### 4.6.2 Traženje uzorka

Algoritam traženja uzorka brzo locira regije na slici koje odgovaraju referentnom uzorku. Algoritam se koristi tako da se unaprijed definira uzorak koji predstavlja objekt kojega na slici tražimo. Traženje uzorka se odvija neovisno o varijacijama u osvjetljenju, zamućenosti, šumu i geometrijskim transformacijama kao što su pomaci, rotacije ili skaliranje uzorka.

Traženje uzorka je jedan od najvažnijih alata u vizijskim sustavima zbog upotrebe u različitim aplikacijama. Traženje uzorka se može koristiti kako bi se definirali položaji objekata na slici, mjerile različite dimenzije ili vršila inspekcija prisutnosti i slično (Slika 4.11). Algoritam traženja uzorka prvo treba locirati referentni uzorak na slici. Kada je uzorak na slici skaliran ili rotiran, algoritam prepoznavanja uzorka može detektirati slijedeće instance na slici:

- Uzorak na slici
- Položaj uzorka na slici
- Orijentaciju uzorka
- Višestruke uzorke na slici.




Slika 4.11 Traženje uzorka [6]

#### 4.6.3 Traženje geometrijskih značajki

Traženje geometrijskih značajki locira regije na slici koje odgovaraju nekom referentnom modelu ili uzorku. Traženje geometrijskih značajki je algoritam koji je specijaliziran da prepoznaje uzorke distinktivnih geometrijskih informacija i oblika (Slika 4.12).

Kada se koristi traženje geometrijskih značajki unaprijed se definira model ili uzorak, a nakon toga algoritam traži instance pri svakoj inspekciji slike. Traženje geometrijskih značajki je algoritam koji funkcionira neovisno o varijacijama u osvjetljenju, zamućenosti, šumu i geometrijskim transformacijama kao što su pomicanje, rotacija ili skaliranje uzorka. Traženje geometrijskih uzoraka se koristi za:

- Mjerenje – Mjerenje duljina, promjera, kuteva i drugih kritičnih dimenzija
- Inspekcija – Otkrivaju se nesavršenosti kao što su oštećenja površine, objekti koji nedostaju i slično
- Položaj – Određuje se položaj i orijentacija poznatog objekta tako da se lociraju referentne točke na objektu ili karakteristični uzorci
- Sortiranje – Sortiranje objekata bazirano na obliku i/ili veličini. Algoritam daje informaciju o lokaciji, orijentaciji ili veličini pojedinih objekata.



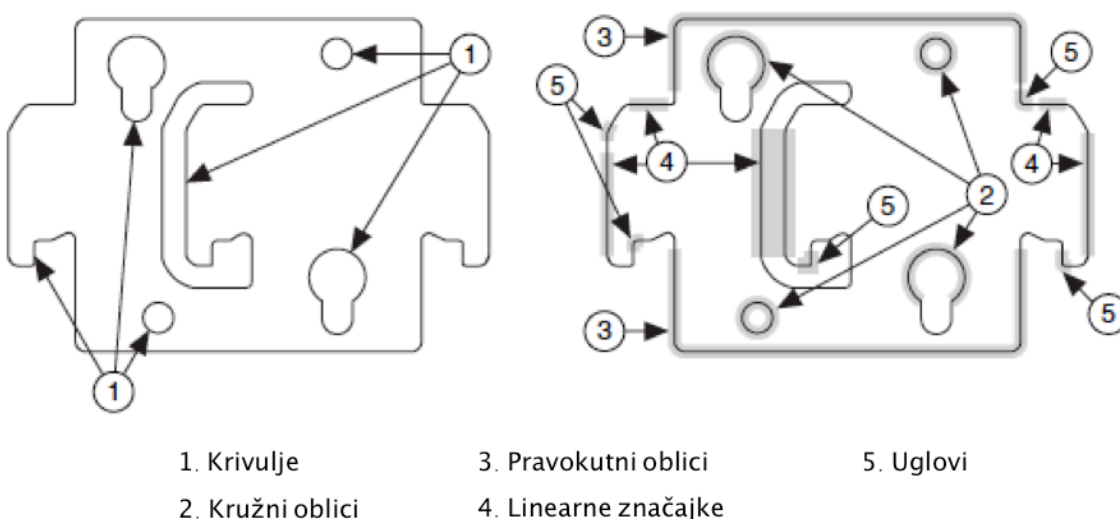
Slika 4.12 Primjeri značajki za geometrijsko prepoznavanje [6]

Algoritam koristi informaciju o intenzitetu piksela koji se nalazi na slici uzorka kao glavnim alatom za pretragu. Geometrijske značajke mogu se kretati od skroz jednostavnih, kao što su rubovi ili krivulje pa do složenih kao što su geometrijski oblici. Proces prepoznavanja geometrijskih značajki se sastoji od dvije faze:

- Faza učenja
- Faza prepoznavanja.

Tijekom faze učenja algoritam ekstraktira geometrijske značajke sa slike koja služi kao model za učenje.

Tijekom faze prepoznavanja uzoraka algoritam ekstraktira geometrijske značajke sa slike koja je dobivena akvizicijom, a koji odgovaraju uzorku na slici koja je bila obrazac za učenje.




Slika 4.13 Geometrijske informacije korištene za prepoznavanje [6]

#### 4.6.4 Mjerenje dimenzija

Algoritmi za mjerenje dimenzija omogućavaju dobivanje kritičnih dimenzija kao što su udaljenosti kutevi, površine, položaj linija i kružnica kao i mjerenje količina. Dobiveni podatci mogu se koristiti na razne načine i za razne primjene. Ljudska inspekcija ovih značajki je zamorna, vremenski zahtjevnja i nije konzistentna. Vizijski sustavi takve zadaće odrađuju s lakoćom. Ovi algoritmi se koriste kada se neke odluke donose u ovisnosti o kritičnim informacijama vezane uz dimenzije objekata na sceni, a koji su dobiveni vizijskim sustavom. Proces mjerenja se sastoji od četiri koraka:

- Lociranje komponenti ili dijelova na slici
- Lociranje ključnih značajki objekata
- Izračun dimenzija korištenjem značajki
- Usporedba rezultata sa referentnim .



Slika 4.14 Mjerenje dimenzija značajki objekta [6]


Sve mjere su definirane u odnosu na koordinatni sustav. Koordinatni sustav je baziran na specifičnostima značajki objekta kojeg promatramo i koji se tada koristi kao referenca za mjerenje. Prvo je potrebno odabrati značajku na objektu koja se uvijek i lako detektira. Poželjno je definirati regiju interesa kako se ne bi bespotrebno pregledavala cijela slika i eventualno omogućila pojava krivih procjena. Osovni koraci pri definiranju algoritma za mjerenje dimenzija su:

- Definiranje koordinatnog sustava, softver kreira koordinatni sustav i prati promjenu lokacije i orijentacije objekata na slici
- Definiranje područja mjerenja unutar referentne slike gdje se želi vršiti mjerenje
- Akvizicija slike na kojoj je objekt odnosno značajke koje mjerimo
- Ponovno postavljanje koordinatnog sustava koje vrši softver ovisno o promjeni značajki i položaja objekta unutar područja mjerenja
- Mjerenje na osnovu prethodno definiranih parametara gdje se dobiva mjera koja predstavlja razliku promjene između referentne i mjerene slike.

## 5. TEHNIČKE KARAKTERISTIKE SUSTAVA

Kako je zadatak rada bio procjena kretanja predmeta rada vizijskim sustavom bilo je neophodno osigurati sve potrebne komponente sustava koje su već spominjane u prethodnim poglavljima. Osim osnovnih komponenti vizijskog sustava u projekt su bile uključeni i okolni sustavi bez kojih aplikacija ne bi bila potpuna. Dodatni sustavi koji su korišteni su sustav za dobavu dijelova putem pokretne trake, kao i kontroler Allen Bradley kako bi se cjelokupni projekt mogao ostvariti. U konačnici, navedeni sustav uključuje (Slika 5.1):

- Računalo
- Vizijski sustav
- PLC
- Senzori
- Pokretna traka
- Predmet rada.




Slika 5.1 Komponente sustava

Na prethodnoj slici su vidljive nabrojane komponente sustava i osnovna interakcija koja se ostvaruje među komponentama sustava. Središnji dio sustava je računalo. Preko računala korisnik upravlja navedenim sustavom i njegovim komponentama. Računalo posjeduje softver s kojim ostvaruje komunikaciju sa Allen Bradley kontrolerom i National Instruments vizijskim sustavom.

Svaki od ta dva navedena podsustava komunicira sa ostalim komponentama sustava. Allen Bradley kontroler prima impulse od senzora blizine kako bi izvršavao zadaću mjerenja vremena aktivacije pojedinih senzora blizine. National Instruments vizijski sustav prima impulse sa senzora blizine kako bi se pokrenuo proces akvizicije slike kada predmet rada prođe pored senzora blizine. Dostavna traka nasumično dostavlja uzorke nad kojima se izvršava proces mjerenja.

Kako je već navedeno, zadatak ovog rada je bio procjena kretanja predmeta rada vizijskim sustavom. Koncept rješenja zadatka dan je shematskim prikazom (Slika 5.2). Procjenu kretanja predmeta rada odnosno brzinu kretanja predmeta u prostoru određuje algoritam vizijskog sustava. U isto vrijeme drugi sustav mjeri vrijeme, odnosno brzinu kretanja predmeta rada pomoću senzora blizine, te se dobivena vremena jednog i drugog sustava uspoređuju kako bi se dobio podatak o odstupanju vrijednosti koje generira vizijski sustav.



Slika 5.2 Shematski prikaz rada vizijskog sustava



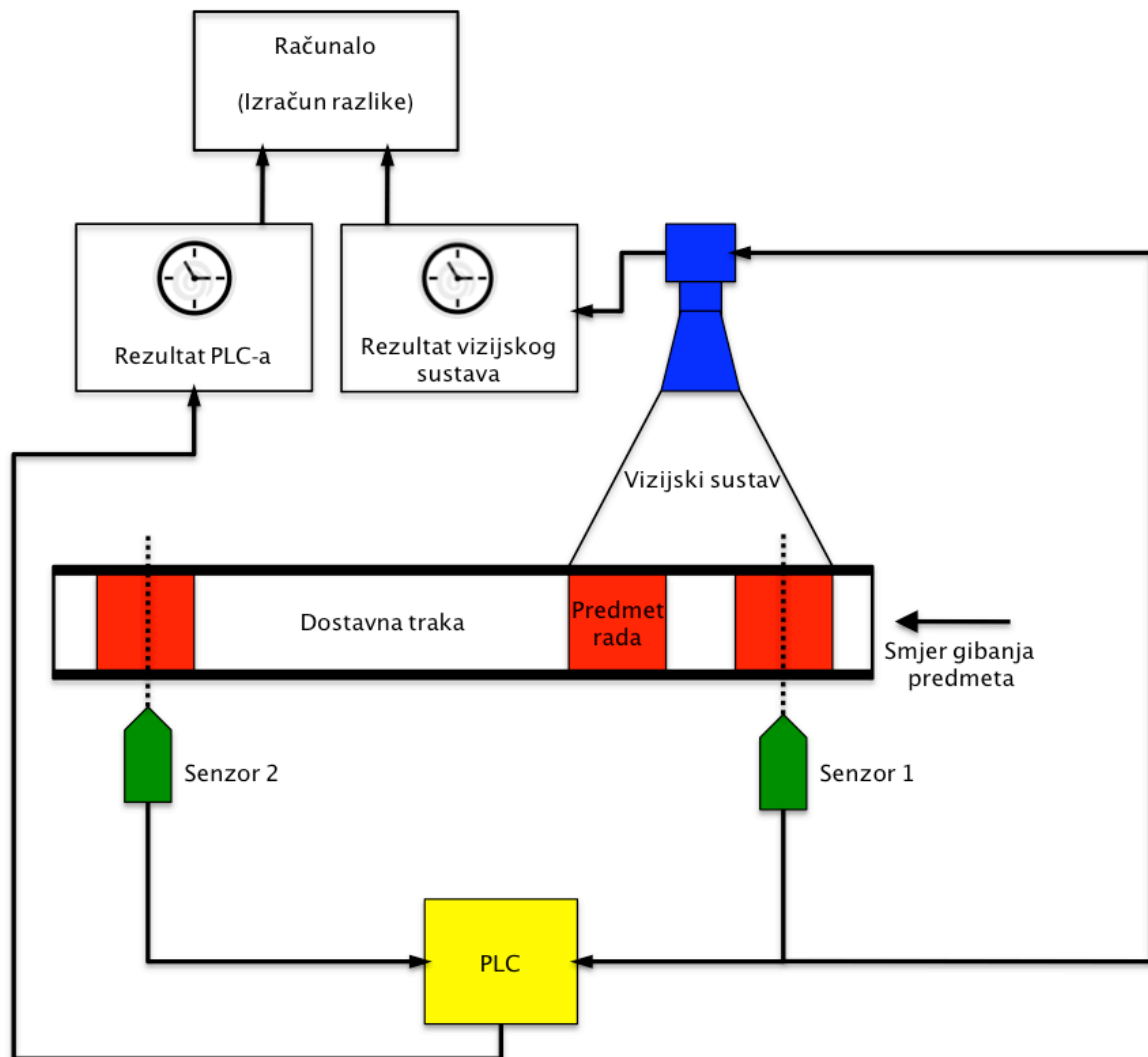
Naime, vizijski sustav je sustav koji je iznimno podložan složenosti procesiranja slike. Kako algoritmi kojima se obrađuje i analizira slika znatno utječu na vrijeme procesiranja sustava tako raste i greška rezultata koji generira vizijski sustav. Zbog toga je uvedeno mjerenje vremena prolaska predmeta rada na dostavnoj traci senzorima blizine kako bi se znalo točno vrijeme koje je prošlo da bi predmet došao iz jednog položaja u drugi. Cijeli proces sastoji se od slijedećih koraka (Slika 5.3):

1. Nasumično dostavljanje predmeta rada putem dostavne trake
2. Aktivacija prvog senzora blizine predmetom rada
3. Istovremena akvizicija slike vizijskim sustavom i pokretanje tajmera putem signala prvog senzora blizine na PLC-u
4. Automatska akvizicija druge slike vizijskim sustavom nakon perioda čekanja u odnosu na prvu akviziciju
5. Procjena pređenog puta predmeta rada vizijskim sustavom
6. Aktivacija drugog senzora blizine predmetom rada
7. Zaustavljanje tajmera putem signala drugog senzora blizine
8. Izračun vremena prolaska predmeta rada koje je prošlo od aktivacije prvog do aktivacije drugog senzora blizine na PLC sustavu
9. Izračun greške na računalu korištenjem podataka dobivenih vizijskim sustavom i PLC-om.

U osnovi, može se zaključiti da vizijski sustav računa brzinu gibanja predmeta rada. Na osnovu toga može se izračunati vrijeme kada će se predmet rada naći na poziciji gdje dolazi do aktivacije drugog senzora blizine. Budući da se i to vrijeme stvarno motri i zapisuje u konačnici se uspoređuje pretpostavljeno vrijeme sa onim izmjerenim te se dolazi do vrijednosti na osnovu koje računamo grešku procjene vizijskog sustava. Ako se ispitivanjem i mjerenjem pokaže da je rasipanje rezultata konstantno odnosno da je greška koju generira vizijski sustav konstantna ona se može upotrijebiti za daljnje implementacije unutar sustava.

Sa tom greškom se kasnije može računati kada se algoritam procjene kretanja predmeta rada bude povezivao sa robotskim sustavom. Na osnovu te greške može se izračunati maksimalno odstupanje položaja predmeta rada u nekom kasnijem vremenskom trenutku, kao i sam položaj predmeta rada te se na taj način robotu može definirati u kojem položaju se u određenom vremenskom

trenutku mora nalaziti prihvatnica kako bi na vrijeme i u točnom položaju vršio interakciju sa predmetom rada.



Slika 5.3 Shematski prikaz rada cjelokupnog sustava

## 5.1 Kamera

Hardverski dio vizijskog sustava sastoji se od kamere, frame grabbera i objektiva. U slijedećoj tablici dani su osnovni parametri kamere (Tablica 5.1)


Tablica 5.1 Specifikacije kamere Basler Scout [7]

Specifikacije	scA1000-30gm/gc
Veličina senzora (HxV piksela)	gm: 1034 x 779 gc: 1032 x 778
Vrsta senzora	Sony ICX204 AL/AK
	Progressive scan CCD
Optička veličina	1/3"
Veličina piksela	4.65 $\mu\text{m}$ x 4.65 $\mu\text{m}$
Maksimalni broj sličica u punoj rezoluciji	31 fps
Mono / boja	All models available in mono or color
Izlazni protokoli	Fast Ethernet (100 Mbits/s) or Gigabit Ethernet (1000 Mbits/s)
Dubina/bitovi	12 bits
Sinkronizacija	Via external trigger signal or via software
Kontrola ekspozicije	Programmable via the camera API
Napajanje	+12 to +24 VDC, (min. +11.3 VDC, absolute max. +30.0 VDC), < 1% ripple
	3.0 W @ 12 V
I/O portovi	2 opto-isolated input ports and 4 opto-isolated output ports
Prihvat objektiva	C-mount (CS-mount optional)


Budući da je kamera već bila dostupna nije bilo potrebe niti mogućnosti nabavljati novu kameru. Stoga je trebalo sa danom kamerom riješiti problematiku navedenu u zadatku. Ispostavilo se da je kamera zadovoljavajuće odradila zadatak pa nije bilo potrebe za eventualnom promjenom modela kamere. Svi ključni parametri kamere bili su dostatni za izvršavanje funkcije u vizijskom sustavu, kao što su dostatna kvaliteta senzora, odnosno rezolucija, te dovoljno velik broj sličica u sekundi koje je kamera u stanju snimiti.

Početna pozicija kamere unutar montažnog sustava, gdje se kamera koristila za prethodne zadaće nije bila zadovoljavajuća. Točnije, zbog specifičnosti zadatka, odnosno procjene kretanja predmeta rada bilo je potrebno pronaći prikladnu poziciju kako bi kamera nesmetano vršila svoju funkciju. Nakon odabira prikladne

lokacije kamera je pričvršćena na željenu poziciju na nosač, odnosno aluminijski profil i nosivu ploču. Osnovne dimenzije kamere potrebne za montažu vide se na slijedećoj slici (Slika 5.4) kao i konačni položaj kamere u sustavu (Slika 5.5).




Slika 5.4 Osnovne dimenzije kamere [7]



Slika 5.5 Položaj kamere u montažnom sustavu

## 5.2 Procesorska jedinica vizijskog sustava

Osnova svakog vizijskog sustava je jedinica za procesiranje slike. Za potrebe ovog rada korišten je kompaktni vizijski sustav National Instruments Compact Vision System, NI CVS – 1450 Series (Slika 5.6). Sustav je već bio dostupan i nije bilo mogućnosti odabira modela. Danim sustavom trebalo je riješiti problem, no pokazalo se da postoje neka ozbiljna ograničenja koja se inače javljaju kod kompaktnih sustava. Ta ograničenja se tiču dostupnih softverskih alata koji dolaze sa takvim sustavima. Naime alati i algoritmi su često osnovni i ograničene konfigurabilnosti što je u ovome slučaju i bio problem. Ipak, same hardverske specifikacije sustava su dostatne i problematika, odnosno nedostaci u ovoj primjeni se tiču isključivo softvera.



- |                            |                           |                   |
|----------------------------|---------------------------|-------------------|
| 1 LED napajanja            | 5 IEEE 1394a portovi      | 9 VGA             |
| 2 LED statusa              | 6 TTL I/O i izolirani I/O | 10 RS-232 Serial  |
| 3 Izolirani digitalni ulaz | 7 Reset                   | 11 RJ-45 Ethernet |
| 4 TTL digitalni izlaz      | 8 DIP sklopke             |                   |


Slika 5.6 CVS-1450 Series prednja ploča [8]

Navedeni sustav radi sa dva tipa softvera:

- NI Vision Builder for Automated Inspection (VBAI)
- LabVIEW Real-Time Module


Oba softvera su proizvod tvrtke National Instruments. NI VBAI softver predstavlja uobičajeno, integrirano rješenje sa unaprijed definiranim prilagodljivim alatima ali ne nudi potpuno prilagodljivo rješenje, dok LabVIEW predstavlja softversku bazu koja je potpuno konfigurabilna no iznimno kompleksna i kao takva se koristi za složene aplikacije.

Nakon što je definiran položaj kamere u sustavu bilo je potrebno zbog ograničenosti u duljini kablova izvršiti i prikladnu montažu procesorske jedinice vizijskog sustava (Slika 5.7, Slika 5.9).



Slika 5.7 Osnovne dimenzije CVS-1450 Series modula [8]

Procesorski modul CVS-1450 Series je povezan sa Basler Scout kamerom (navedenom u prethodnom poglavlju) putem IEEE 1394 protokola. Osim toga, navedeni modul je povezan sa zasebnim monitorom koji omogućava praćenje inspekcije u stvarnom vremenu putem VGA kabela. Osim toga procesorski modul povezan je i sa računalom na kojem se nalazi razvojni softver putem Ethernet protokola. Kako bi se omogućila komunikacija sa ostalim uređajima na procesorski modul spojena je i I/O razvojna ploča putem 44-Pin DSUB konektora (Slika 5.8).




- 1 Standard Ethernet kabl koji povezuje CVS 1450 modul sa Ethernet hub-om
- 2 Standard Ethernet kabl koji povezuje Ethernet hub sa razvojnim računalom
- 3 Ethernet hub ili neki drugi mrežni port
- 4 44-DSUB konektor koji povezuje I-O modul sa CVS 1450 modulom

Slika 5.8 Shematski prikaz povezivanja CVS 1450 modula

Putem 44-Pin DSUB konektora sustav komunicira sa I-O modulom na kojeg se spajaju razni vanjski analogni i digitalni signali kako bi se omogućila komunikacija vizijskog sustava sa drugim uređajima. Digitalne I/O funkcije su dostupne kroz 2 TTL ulaza, 10 TTL izlaza, 13 izoliranih ulaza i 4 izolirana izlaza.



TTL je brzo izmjenjivi, 5 V, digitalni standardizirani signal koji se uobičajeno koristi u aplikacijama koje zahtijevaju visoku preciznost, kao što je okidanje kamere. TTL ulazi i izlazi ne zahtijevaju zasebno napajanje. Ulazni signali se mogu koristiti kao okidači, kao selekcija portova ili da bi se čitali kvadrturni enkoderni. Izlazni portovi se koriste da bi se kontrolirala kamera odnosno ekspozicija, osvjetljenje, inspekcijski rezultati, reset funkcija ili komunikacija sa PLC-om.




Slika 5.9 Položaj CVS 1450 modula u montažnom sustavu



### 5.3 I/O Modul

Da bi procesorska jedinica vizijskog sustava komunicirala sa ostalim hardverom potreban je I/O terminal. Uz postojeće module koji su navedeni u prethodnim poglavljima korišten je i I/O terminal kako bi se vizijski sustav povezao sa senzorima blizine u svrhu okidanja kamere i određivanja početka akvizicije slike. Korišteni modul je National Instruments NI Vision I/O Terminal Block and Prototyping Accessory (Slika 5.10).




- 1 LED diode koje pokazuju koji TTL ulazi i izlazi su aktivni
- 2 37-pin D-SUB konektor
- 3 LED diode koje pokazuju aktivne linije za selekciju proizvoda
- 4 LED diode koje pokazuju da li je ISO PWR aktivan
- 5 LED diode koje pokazuju koji ISO ulazi su aktivni
- 6 Prekidači koji omogućuju upravljanje TTL signalima
- 7 LED diode koje pokazuju koji ISO izlazi su aktivni
- 8 Potenciometar za reguliranje kvadraturnog enkoder signala
- 9 LED diode koje pokazuju da li je modul u demo modu
- 10 DIP prekidač za aktivaciju modova
- 11 Navigacijski prekidači

Slika 5.10 NI Vision I/O Accessory prednja ploča [9]

Navedeni modul je opremljen terminalima sa vijcima za lako povezivanje i potrebnim konektorima za izravno povezivanje sa NI CVS 1450 vizijskim sustavom. I/O terminal posjeduje LED diode za svaki signal, kako bi se lako pratilo stanje i rad sustava.

Na navedeni I/O terminal spojeni su senzori blizine čime je sa ostalim hardverom (Basler Scout kamera, NI CVS 1450 modul) vizijski sustav hardverski potpun i omogućava izvršavanje zadatka praćenja predmeta rada. Modul je radi ograničenja u duljini kablova, zbog povezivanja sa ostalim hardverom, montiran u blizini kamere kao i procesorski modul (Slika 5.11).



Slika 5.11 Položaj I/O Accessory modula u montažnom sustavu

## 5.4 Ostale hardverske komponente

Od ostalih važnih elemenata sustava kojim se vršila procjena kretanja predmeta rada, a bez kojih sustav ne bi mogao funkcionirati, bitno je napomenuti slijedeće:

- Senzor blizine
- PLC
- Objektiv
- Dostavna traka.

### ***Senzor blizine***


Za potrebe mjerenja vremena prolaska predmeta rada korišteni su osim vizijskog sustava i senzori blizine koji su pokretali i zaustavljali tajmer kako bi se omogućilo praćenje referentnog vremena (Slika 5.12).

Senzori blizine koji su korišteni su kapacitivni senzori iz Festo Didactic programa, a koji su već bili unaprijed dostupni. Senzor blizine je senzor koji je u mogućnosti detektirati prisutnost objekata u blizini bez potrebe za fizičkim kontaktom. Odabrani su kapacitivni senzori budući da mogu detektirati i prisutnost nemetalnih predmeta dok induktivni senzori zbog principa rada detektiraju samo metalne predmete.



Slika 5.12 Kapacitivni senzor

Senzori blizine montirani su pokraj pokretne trake kako bi mogli detektirati prolazak predmeta rada (Slika 5.13). Senzori su pričvršćeni na aluminijski profil na međusobnoj udaljenosti od 700 mm. Položaj prvog senzora diktira vidno polje kamere, budući da je prvi senzor odgovoran za pokretanje akvizicije slike. Stoga je položaj prvog senzora ključan kako bi se omogućila pravovremena akvizicija i kako bi predmet rada prilikom akvizicije bio na željenom mjestu na slici. Na taj nači osigurava se pravilna kasnija obrada slike i prisutnost svih potrebnih značajki na slici koja se procesira.



Slika 5.13 Položaj senzora blizine u montažnom sustavu



## PLC

Da bi sustav mogao mjeriti vrijeme koje je proteklo od aktiviranja prvog senzora blizine do aktiviranja drugog senzora blizine koristio se programibilni logički kontroler. Budući da je dostupan vizijski sustav bio iz porodice kompaktnih vizijskih sustava, imao je nekih ozbiljnih ograničenja koja su utjecala na nemogućnost dovoljno točnog mjerenja vremena, a koje je ključno za ovakav tip aplikacije, budući da je vrijeme ključni parametar kojim se vrši procjena kretanja predmeta rada vizijskim sustavom.

Za povezivanje senzora blizine korišten je dostupni PLC tvrtke Allen Bradley, model L32E (Slika 5.14). Kako osim aktivacije i zaustavljanja tajmera navedeni PLC nije imao drugu primjenu u ovom sustavu, neće se detaljno razmatrati specifikacije kontrolera.



Slika 5.14 Allen Bradley L32E PLC

## Objektiv

Da bi vizijski sustav bio potpun i da bi mogao vršiti svoju zadaću, kameru vizijskog sustava (Basler Scout) bilo je potrebno opremiti odgovarajućim objektivom. Odabran je objektiv tvrtke Cosmocar Pentax CCTV Camera Lens slijedećih specifikacija:

- Žarišna duljina 12.5 mm
- Promjer leće 1:1,8
- C-Mount prihvat.




Slika 5.15 Prikaz objektiva


Zbog ograničenog prostora nije bilo moguće dodatno podignuti kameru u odnosu na predmet rada pa je scena snimanja bila relativno mala. Zbog prirode mjerenja povoljniji slučaj bi bio kada bi kamera bila udaljenija od predmeta rada, kako bi polje pogleda bilo veće, a samim time promatrani put koji predmet rada prođe unutar kadra tijekom snimanja bio bi veći.

## 5.5 Predmet rada

Od preostalih tehničkih parametara potrebno je definirati i opisati promatrani predmet rada budući da je on okosnica sustava. Kako je već navedeno, potrebno je izvršiti procjenu kretanja rada vizijskim sustavom. Predmet rada dolazi u kadar vizijskog sustava putem pokretne trake. Predmet rada uvijek ima istu orijentaciju i giba se po pravcu tako da je potrebno pratiti promjene u gibanju duž samo jedne osi. Predmet rada je sklopka (Slika 5.16), a pomoću dostavne trake se dostavlja na paleti (5.17).



Slika 5.16 Dimenzije sklopke i palete



Slika 5.17 Prikaz sklopke na paleti

## 6. VIZIJSKI PROCES

Nakon što je hardverski dio sustava potpuno i pravilno definiran i nakon što se probnim inspekcijama i podešavanjem sustava utvrdilo da sustav funkcionira pravilno, pristupilo se izradi algoritma za praćenje i procjenu kretanja predmeta rada navedenim vizijskim sustavom.

U ovom stadiju problemu se pristupa sa softverske strane. Budući da navedeni vizijski sustav tvrtke National Instruments spada u grupu kompaktnih vizijskih sustava omogućeno je programiranje sustava putem dvije vrste softvera:

- NI Vision Builder For Automated Inspection (VBAI)
- LabVIEW.

Zbog kompatibilnosti i praktične upotrebe upotrebljen je izvorni softver VBAI no radi njegovih ograničenja pristupilo se upotrebi dodatnih rješenja kako bi se procjena kretanja predmeta rada izvršavala pravilno.

Naime, osnovni zahtjev prilikom izrade ovog projekta bila je točnost. Bez iskorištavanja maksimalne točnosti koju nam sustav nudi rezultati bi bili neupotrebljivi i nekonzistentni. Kako se kasnije pokazalo VBAI je pokazao neke ozbiljne nedostatke za traženu primjenu. Među osnovnim alatima ne nalazi se niti jedan timer iako se spretnim definiranjem algoritma i to može zaobići, no na taj način dobivena točnost koju sustav postiže pri mjerenju iznosi samo jednu sekundu, što je neprihvatljivo.

Rješenju problema se pokušalo doskočiti na način da se napiše zasebna skripta u softveru LabVIEW. LabVIEW je softverska baza koja omogućuje potpunu definiciju i manipulaciju algoritama koji se onda mogu koristiti na brojnim kompatibilnim uređajima pa tako i navedenom NI CVS 1450 vizijskom sustavu. Iako je to točno, specifični zahtjev nije bilo moguće riješiti niti na taj način. Zasebna skripta koja je predstavljala timer napisana je u softveru LabVIEW. Budući da softver VBAI omogućuje pokretanje skripti pisanih u softveru LabVIEW ideja je bila da se timer algoritam u softveru VBAI pokreće i poziva kao zasebna inspekcija što teoretski i treba funkcionirati. No radi složene baze softvera koji se u pozadini pokreću na prethodno navedenim sustavima i koji omogućuju emulaciju softvera trećih strana navedeni timer algoritam nije bilo moguće na taj način pokretati pomoću VBAI-a što su kasnije potvrdili i National Instrumentsovi razvojni inženjeri.

Preostala su dva rješenja. Da se cjelokupni algoritam izvorno napiše u softveru LabVIEW ili da se upotrijebi drugi sustav samo za izradu timera. Prvo rješenje je odbačeno jer bi cjelokupni prethodan rad na algoritmu u VBAI softveru bio bespotreban, te stoga što je takvo rješenje iznimno vremenski zahtjevno i zahtjeva potpuno drugačiji pristup. Odlučeno je da će se funkcija timera izvršavati na zasebnom sustavu, PLC-u Allen Bradley što se pokazalo kao praktično i dobro rješenje.




## 6.1 Podešavanje vizijskog sustava i kalibracija

Vizijski sustav vrši akviziciju i procesiranje slike. Prije početka akvizicije potrebno je sustav pravilno podesiti odnosno kalibrirati. Vrste slika sa kojima radi NI CVS 1450 vizijski sustav su:

- BMP
- TIFF
- PNG
- JPEG
- AIPD.

Na sljedećoj slici vidljivo je kako NI vizijski sustav tumači sliku u memoriji (Slika 6.1)




- |                 |                         |                           |                 |
|-----------------|-------------------------|---------------------------|-----------------|
| 1 Slika         | 3 Vertikalna rezolucija | 5 Horizontalna rezolucija | 7 Širina linije |
| 2 Granica slike | 4 Lijevo poravnavanje   | 6 Desno poravnavanje      |                 |

Slika 6.1 Prikaz tumačenja slike NI vizijskog sustava [10]

Uz sliku, pohranjena slika uključuje i dodatne redove i stupce koji se nazivaju granica slike te lijevo i desno poravnavanje. Regije poravnavanja osiguravaju da prvi piksel slike bude pravilno postavljen u matrici slike. Poravnavanje slike povećava brzinu procesiranja i do 30%.


Prije nego što se izvrši akvizicija slike te procesiranje potrebno je još dodatno podesiti vizijski sustav. Faktori koji izravno utječu na vizijski sustav, a time i kvalitetu akvizicije su polje pogleda, radna udaljenost, rezolucija, dubinska oštrina i veličina senzora (Slika 6.2).



- |                    |                    |                    |                      |
|--------------------|--------------------|--------------------|----------------------|
| 1 Rezolucija       | 3 Radna udaljenost | 5 Dubinska oštrina | 7 Piksel             |
| 2 Područje pogleda | 4 Veličina senzora | 6 Slika            | 8 Rezolucija piksela |


Slika 6.2 Osnovni parametri vizijskog sustava [10]

Perspektiva je važan faktor koj utječe na dobiveni rezultat. Greške koje se događaju zbog loše perspektive su rezultat položaja kamere u odnosu na objekt koji se promatra. Os kamere mora biti okomita u odnosu na predmet rada kada god je to moguće. Nekada je to zbog konfiguracije sustava jednostavno nemoguće izvesti pa se vrši kalibracija kako bi se kompenzirale nastale greške (Slika 6.3).




Slika 6.3 Kut kamere u odnosu na predmet promatranja [10]

Osim perspektive greške u tumačenju i prikazu slike mogu se dogoditi i zbog distorzije koja je rezultat nepravilnosti same leće (Slika 6.4).




Slika 6.4 Pogreška nastala zbog percepcije i distorzije

Kako bi se proces kalibracije dovršio potrebno je definirati poznati set točaka da bi se definirala poveznica između točaka na slici i stvarne lokacije točaka koje odgovaraju realnom svijetu (Slika 6.5). Kalibracijski alati koriste poznate vrijednosti, kako bi izračunali odnos između stvarnih vrijednosti i piksela.



Slika 6.5 Proces kalibracije

Da bi se vrijednosti mjerenja izrazile u stvarnim mjernim jedinicama potrebno je definirati koordinatni sustav. Kalibracijski algoritam određuje smjer horizontalne osi stvarnog svijeta i podešava smjer iste na slici koja se tumači (Slika 6.6). Nakon izvedene kalibracije sustav će pravilno prikazivati mjerne rezultate.



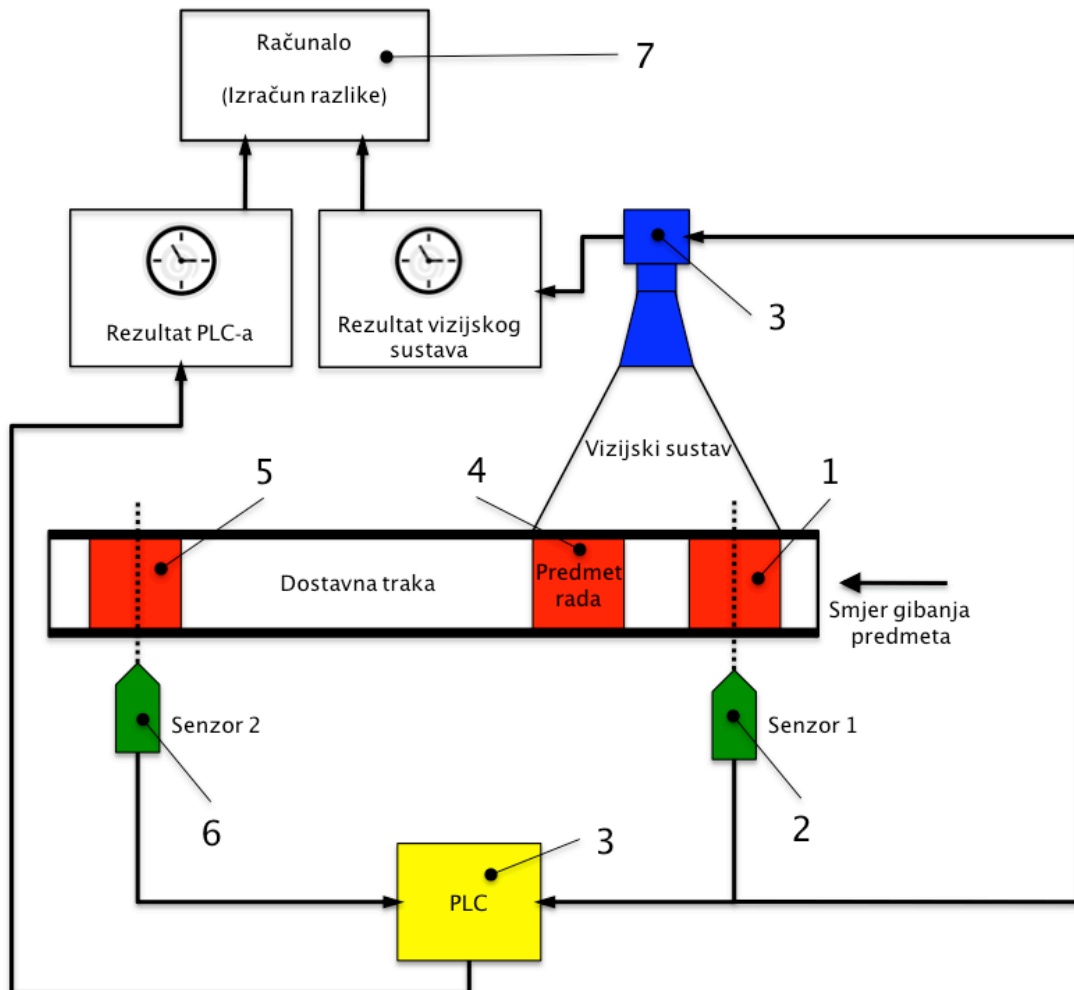
1 Ishodište u stvarnom svijetu

2 Ishodište snimljene slike

Slika 6.6 Ishodište i zakret koordinatnog sustava

## 6.2 Opis procesa

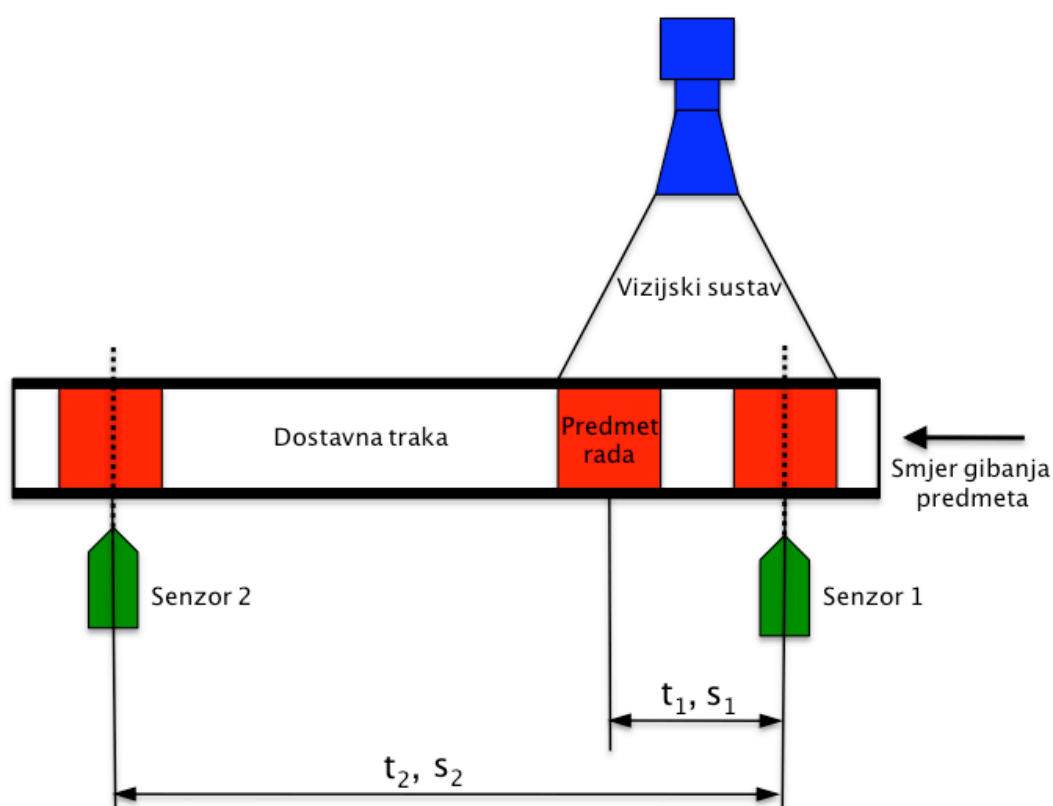
Kako bi se izradio potreban algoritam potrebno je proces koji će vizijski sustav pratiti, u ovom slučaju procjenu kretanja predmeta rada, raščlaniti na korake. U svakom koraku potrebno je definirati ključne parametre i elemente sustava koji će te parametre pratiti ili opisivati (Slika 6.7).



Slika 6.7 Redosljed izvršavanja radnji pri praćenju predmeta rada

1. Translacijom na pokretnoj traci predmet rada dolazi u prvi referentni položaj
2. Nakon dolaska u prvi referentni položaj premet rada aktivira prvi senzor blizine

3. Istovremeno pokretanje tajmera na PLC-u i akvizicija prve slike na vizijem sustavu prvim senzorom blizine
4. Nakon određenog vremenskog perioda slijedi automatska akvizicija druge slike vizijem sustavom dok je predmet rada još uvijek u kadru
5. Daljnjom translacijom na pokretnoj traci predmet rada dolazi u drugi referentni položaj
6. Nakon dolaska u drugi referentni položaj predmet rada aktivira drugi senzor blizine i na PLC-u se zaustavlja tajmer
7. Iz dobivenih podataka računa se odstupanje



$t_2, s_2$  – mjerene vrijednosti

$t_1, s_1$  – izračunate vrijednosti

Slika 6.8 Glavne varijable sustava

Prilikom mjerenja nekih varijabli dolazi do značajnih odstupanja prvenstveno zbog pogreške koju generira vizijski sustav. Varijable koje sustav računa, a to su put koji predmet rada prođe u određenom vremenu, odnosno vrijeme koje je potrebno da se pređe taj put odstupaju od mjerenih vrijednosti zbog procesorskog vremena koje je potrebno da bi vizijski sustav obradio sliku (Slika 6.8). Ključne varijable predstavljaju:

- $t_1$  – vrijeme proteklo između dvije akvizicije slike
- $s_1$  – put koji izračuna vizijski sustav, a koji je predmet prešao za vrijeme  $t_1$
- $t_2$  – vrijeme koje prođe da bi predmet rada prošao unaprijed zadani put
- $s_2$  – put koji pređe predmet rada za vrijeme  $t_2$
- $\Delta t$  – vrijeme  $t_1$  + greška sustava

Vrijeme  $t_2$  je vrijeme koje se mjeri senzorima i čije mjerenje predstavlja referencu. Isto tako, put  $s_2$  predstavlja referentnu, unaprijed poznatu i definiranu vrijednost. Varijable  $t_1$  i  $s_1$  su vrijednosti koje ovise o vizijском procesu i čija se greška traži. Kada se izračuna odstupanje vrijednosti i ako se pokaže da je odstupanje približno kontinuirano, vrijednost odstupanja se može proglasiti konstantom i kasnije se sa njom može pouzdano računati.

Izračunata greška ovisi ne samo o pogrešci vizijskog sustava iako je ona najveća, već i o svim kašnjenjima koja su generirana unutar drugih elemenata sustava. Vremena koja utječu na tu pogrešku su:

- Vrijeme odziva senzora
- Vrijeme aktivacije akvizicije slike
- Vrijeme potrebno za akviziciju slike
- Vrijeme potrebno za procesiranje slike (najveće kašnjenje)
- Vrijeme očitavanja PLC-a
- Ostala vremena.

Nakon izračunate greške odnosno kašnjenja vizijskog sustava, dobiveni rezultat  $\Delta t$  uključuje sva gore navedena vremena.

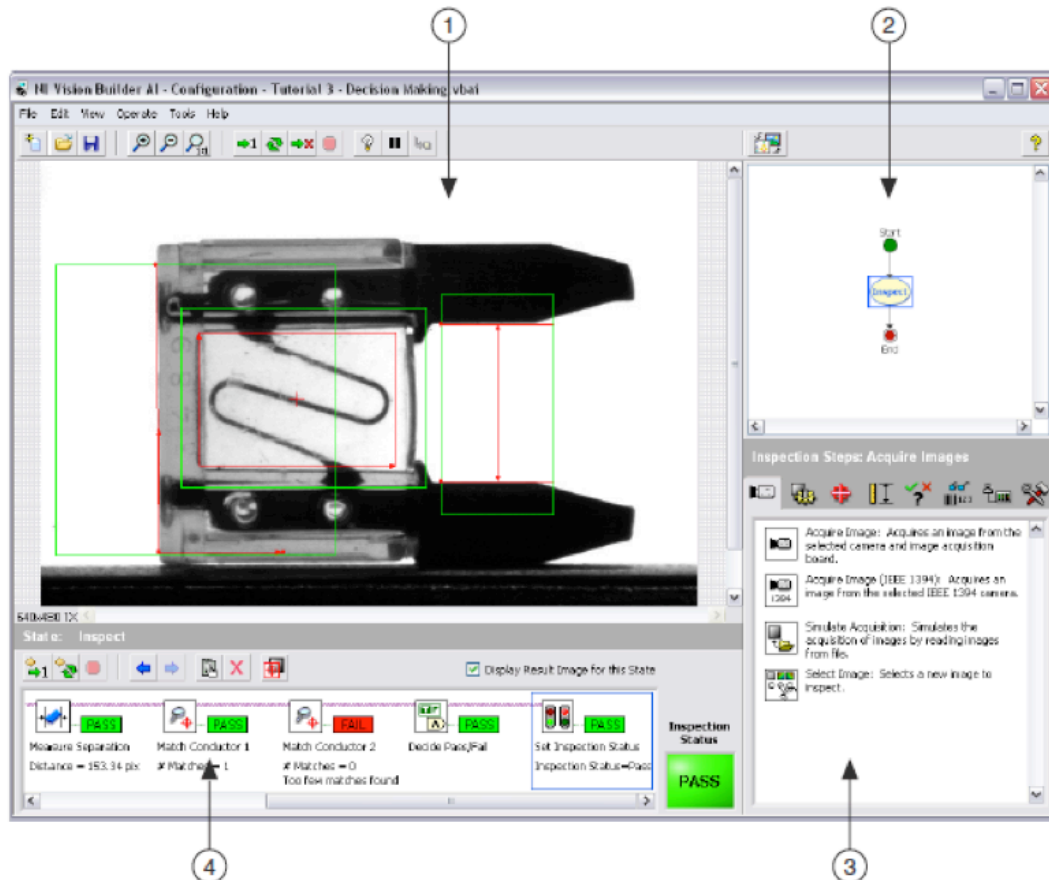
## 6.3 VBAI sučelje

Prije izrade algoritma koji će izvršavati mjerenje putem vizijskog sustava potrebno je proučiti dostupne alate i funkcije koje nudi VBAI softver kako bi se mogao pravilno definirati i izraditi koncept procesa vizijskog sustava. VBAI softver posjeduje dva moda rada:

- Konfiguracijsko sučelje
- Inspekcijsko sučelje.

### Konfiguracijsko sučelje

Unutar konfiguracijskog sučelja vrši se izrada vizijskog procesa i definiraju se radnje koje će vizijski sustav izvršavati (Slika 6.9).



1. Glavni prozor

2. Prozor za pregled

3. Alati

4. Prozor dijagrama toka

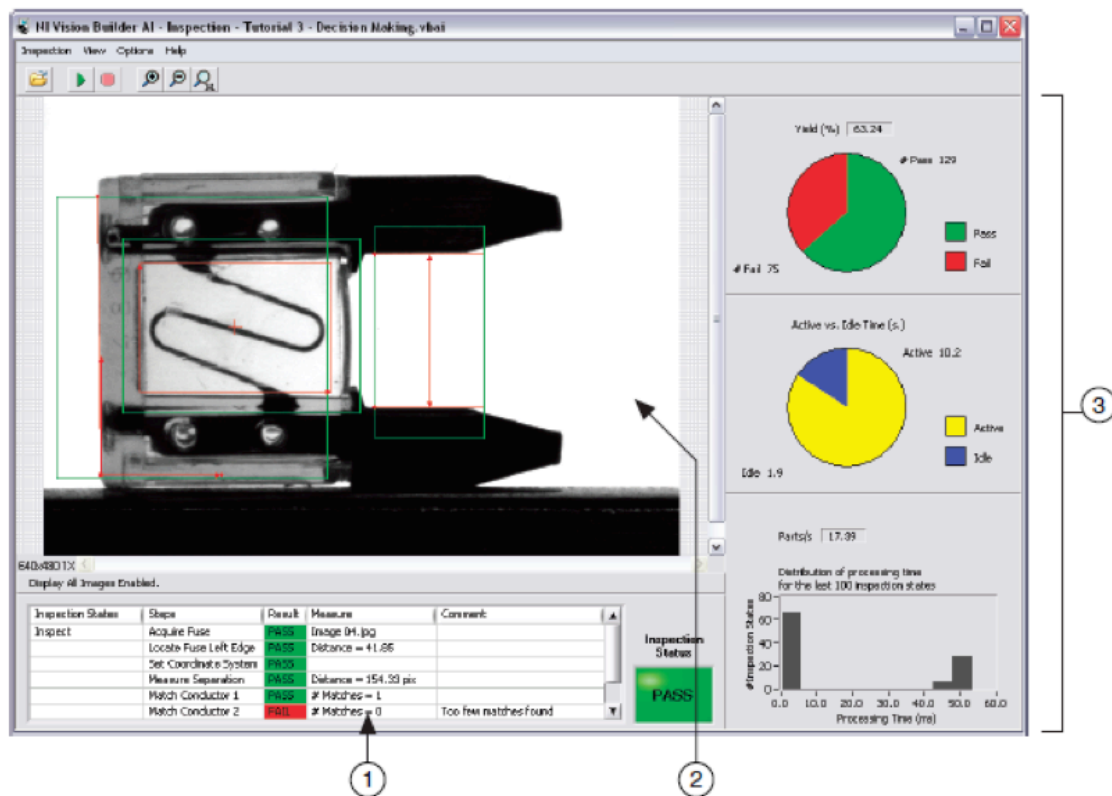
Slika 6. 9 VBAI konfiguracijsko sučelje [10]



- Glavni prozor – prikazuje sliku koja se procesira ili dijagram toka inspekcije
- Prozor za pregled – prikazuje umanjeni prikaz trenutne slike koja se procesira ili dijagram toka inspekcije
- Alati – popis i opis koraka i alata koji se koriste da bi se izradila inspekcija
- Prozor dijagrama toka – prikazuje popis koraka trenutno odabranih unutar inspekcije

### Inspeksijsko sučelje

Unutar inspeksijskog sučelja vrši se pregled stanja sustava i stanja inspekcija dok vizijski sustav vrši svoju zadaću (Slika 6.10).



1. Prikaz rezultata

2. Prozor za prikaz

3. Statistika inspekcije

Slika 6.10 VBAI inspeksijsko sučelje [10]

- Prikaz rezultata – prozor koji prikazuje korake inspekcije po imenu i ispisuje da li je korak zadovoljio ili ne (PASS/FAIL)
- Prozor za prikaz – prikazuje predmet rada nad kojim se vrši inspekcija
- Statistika inspekcije – sadrži tri indikatora koji prikazuju odnos PASS/FAIL, aktivno vrijeme u odnosu na vrijeme mirovanja te vrijeme procesiranja

Gumb	Ime	Opis
	Izvrši inspekciju jednom	Izvršava se jedan ciklus
	Izvršavaj inspekciju u petlji	Izvršava se kontinuirani ciklus
	Izvršavaj inspekciju do otkaza	Izvršava se dok ne dođe do greške
	Zaustavi inspekciju	Inspekcija se zaustavlja
	Pokaži inspekciju	Prikazuje inspekciju kada se uključi navedena opcija
	Pauza	Privremeno se zaustavlja
	Jedan korak	Pomicanje po koracima

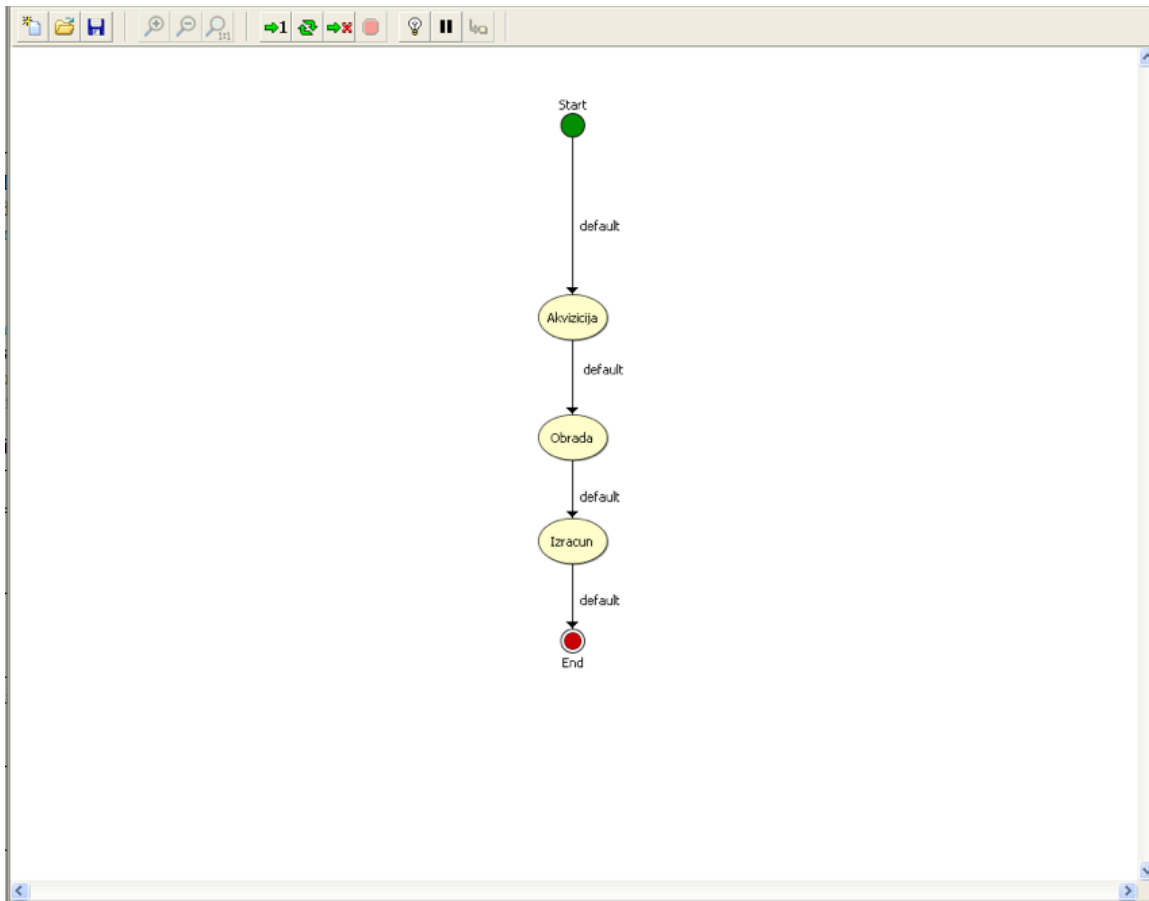
Slika 6.11 Osnovni modovi konfiguracijskog sučelja

## 6.4 Izrada algoritma

Nakon što su raščlanjeni svi elementi vizijskog sustava i poznate sve varijable i parametri uključeni u proces može se pristupiti izradi algoritma vizijskog procesa.

Prvo je definiran glavni dijagram toka (Slika 6.12). Prema dijagramu toka uočljivo je da se inspekcija sastoji od:


- Akvizicija slike
- Obrada slike
- Izračun.



Slika 6.12 Glavni dijagram toka

## Akvizicija slike

Dijagram toka akvizicije slike sastoji se od nekoliko ključnih koraka koji su rezultat zadatka koji vizijski sustav mora izvršavati (Slika 6.13).




Slika 6.13 Koraci procesa akvizicije slike

1. NI – IMAQ I/O Pulse 1 – Prvi korak inspekcije koji definira način akvizicije prve slike. Budući da je početak akvizicije slike definiran dolaskom predmeta rada do senzora blizine tako je u ovom koraku potrebno definirati koji ulazni signal aktivira akviziciju slike. Odabran je ISO ulaz 8 na I/O modulu jer je na taj ulaz spojen prvi senzor blizine.
2. Acquire Image – Drugi korak u kojem se definira sa kojeg će se uređaja uzeti slika nakon što korak 1 pokrene akviziciju. U ovom slučaju radi se o IEEE 1394a kompatibilnom uređaju odnosno kameri Basler Scout koja je odabrana za prikupljanje slika.
3. Vision Assistant – Treći korak u kojemu se slika poboljšava kako bi bila prikladnija za daljnje procesiranje. U ovom koraku se povećava svjetlina slike i naglašava kontrast kako bi traženje značajki bilo pouzdanije.

4. NI – IMAQ I/O Pulse 2 – Četvrti korak inspekcije koji definira način akvizicije druge slike. Budući da je početak akvizicije slike definiran dolaskom predmeta rada do senzora blizine tako je u ovom koraku potrebno definirati način na koji se aktivira akvizicija druge slike. Definirano je automatsko generiranje pulsa i to 150 milisekundi nakon što se detektira NI – IMAQ I/O Pulse 1, odnosno nakon što je predmet rada aktivirao prvi senzor blizine.
5. Acquire Image – Peti korak u kojem se definira sa kojeg će se uređaja uzeti slika nakon što korak 4 pokrene akviziciju. U ovom slučaju radi se o IEEE 1394a kompatibilnom uređaju odnosno kameri Basler Scout koja je odabrana za prikupljanje slika.
6. Vision Assistant – Treći korak u kojemu se slika poboljšava kako bi bila prikladnija za daljnje procesiranje. U ovom koraku se povećava svjetlina slike i naglašava kontrast kako bi traženje značajki bilo pouzdanije.

## Obrada


Obrada slike je proces koji unaprijed definiranim alatima traži značajke na slici kako bi se izvršilo mjerenje pređenog puta predmeta rada



Slika 6.14 Koraci procesa obrade slike

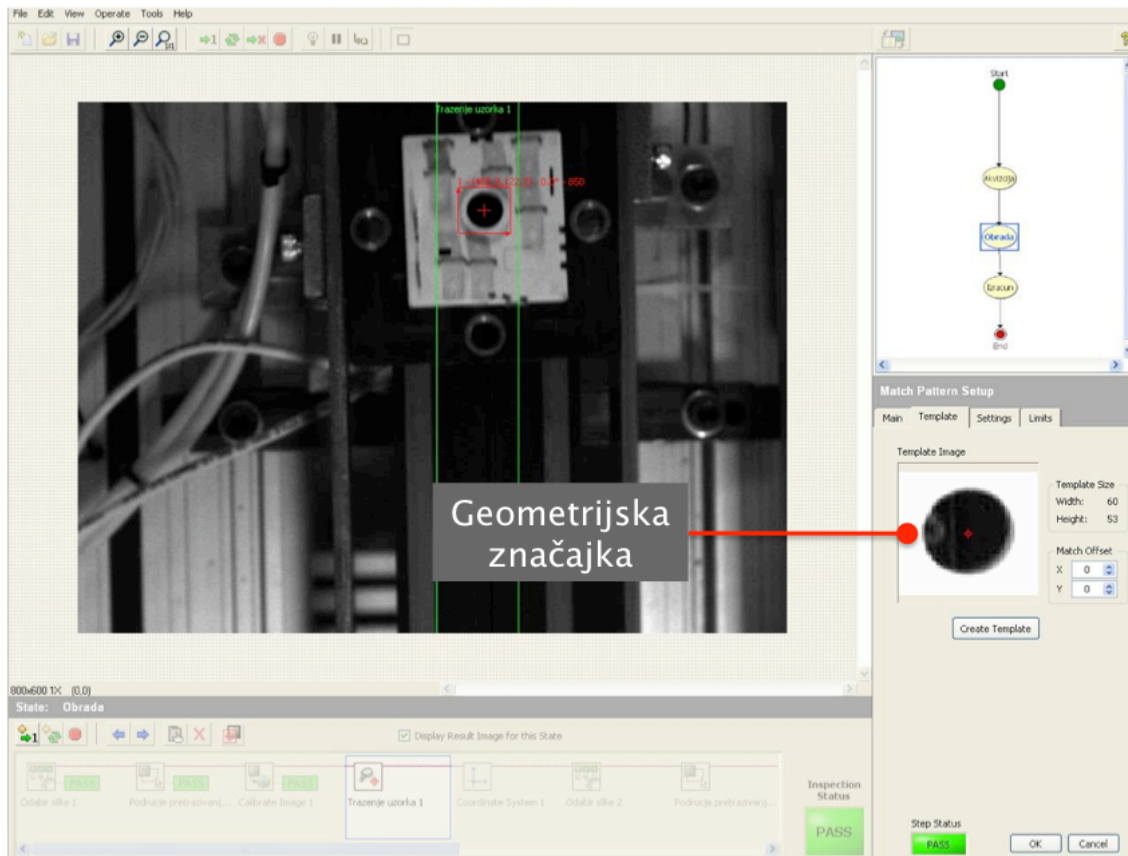
Dijagram toka procesa obrade slike sastoji se od koraka koji su uvjetovani zadatkom koji vizijski sustav mora izvršavati, a to je procjena kretanja predmeta rada (Slika 6.14).

1. Odabir Slike 1 – U prvom koraku obrade slike odabire se prva slika koja će se obrađivati, a to je slika koja je dobivena u drugom koraku akvizicije slike.
2. Područje Pretraživanja 1 – Područje pretraživanja predstavlja zonu interesa. To je zona unutar koje vizijski sustav vrši pretragu značajki i na taj način ubrzava proces obrade slike budući da se procesorsko vrijeme ne troši bespotrebno na procesiranje nebitnih dijelova slike. Zona interesa definirana je na područje kojim prolazi glavna značajka predmeta rada na koju se veže koordinatni sustav (Slika 6.15).



Slika 6.15 Područje pretraživanja

3. Calibrate Image 1 – Kalibracija prve slike. Da bi se dobio točan rezultat potrebno je definirati odnos veličina stvarnog svijeta i prikaza na slici. Korištena je metoda kalibracije pomoću referentne kalibracijske mreže na način da je kalibracijska mreža prethodno učitana te se u ovom koraku inspekcije vizijski sustav poziva na referentnu sliku u odnosu na koju radi usporedbu sa snimljenom slikom te vrši kalibraciju.
4. Traženje Uzorka 1 – Alat koji traži unaprijed definiranu geometrijsku značajku na slici. Značajka koja se traži je lako prepoznatljivi uzorak na predmetu rada budući da je potrebno vezati koordinatni sustav na predmet rada kako bi se mogla mjeriti udaljenost koju je prešao predmet između akvizicije dvije slike. Odabrana značajka je provrt odnosno kružni geometrijski oblik koji se nalazi na predmetu rada (sklopka)(Slika 6.16).

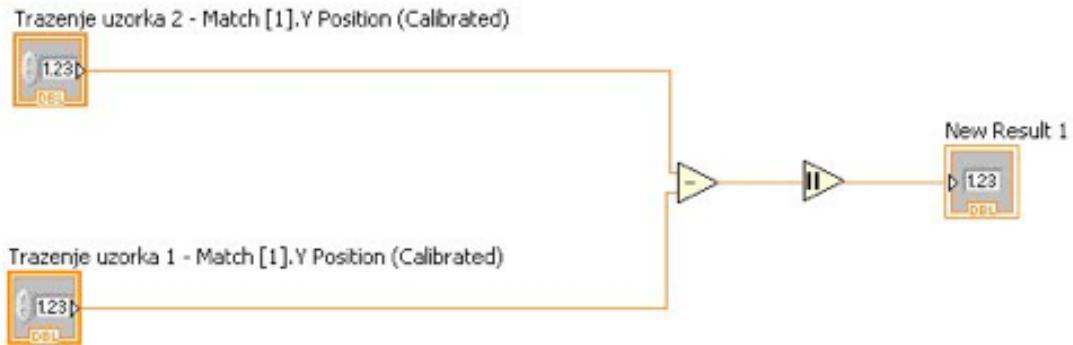


Slika 6.16 Definiranje geometrijske značajke

5. Coordinate System 1 – U ovom koraku se nakon definiranja geometrijske značajke i pronalaska iste koordinatni sustav postavlja u središte kružnog oblika na predmetu rada. Tako vezani koordinatni sustav omogućuje mjerenje udaljenosti što je i ključan zadatak.



6. Calculator – Kalkulator je završni korak obrade slike. Pomoću kalkulatora se računa udaljenost između koordinatnih sustava na obje slike koje su obrađene te se dobiva udaljenost koju je predmet rada prošao od kada je snimljena prva slika do trenutka kada je snimljena druga slika (Slika 6.17).



Slika 6.17 Blok dijagram modela kalkulatora

Prethodno su prikazani koraci samo za obradu prve slike jer su koraci za obradu druge slike potpuno identični.


Nakon što su koraci inspekcije ovako definirani sustav je omogućavao dobro praćenje predmeta rada i procjenu gibanja. Rad prikazanog algoritma bio je iznimno stabilan i nije pokazivao nikakve greške u prepoznavanju kada je predmet rada bio prisutan na slici što znači da su svi koraci inspekcije pravilno definirani.



## 6.5 PLC tajmer

Vizijski sustav vrši procjenu kretanja predmeta rada dok pomoću tajmera na Allen Bradley PLC-u dolazimo do referentne veličine na osnovu koje se vrši usporedba rezultata koje generira vizijski sustav. Vrijeme koje daje tajmer sa PLC-a predstavlja vrijeme koje je prošlo da bi predmet rada aktivirao prvi, a potom i drugi senzor blizine dok to isto vrijeme vizijski sustav računa na osnovu puta kojeg je predmet prešao između dvije akvizicije slike.

Osnovni kod koji je pisan u ladder dijagramu na Allen Bradley PLC-u predstavlja tajmer odnosno mjerenje proteklog vremena koje je prošlo od kada je prvi senzor blizine aktivirao početak mjerenja do trenutka kada je drugi senzor blizine zaustavio mjerenje (Slika 6.18).



Slika 6.18 Osnovni koraci u Ladder dijagramu


Program koji je zadužen za izvršavanje funkcije tajmera sastoji se od nekoliko ključnih naredbi a koje predstavljaju kalsičnu Ladder logiku:

1. Ako je aktiviran prvi senzor i ako nije aktiviran drugi senzor pokreni tajmer
2. Ako u isto vrijeme nije aktiviran drugi senzor drži tajmer aktivnim
3. Tajmer odbrojava vrijeme
4. Ako je aktiviran drugi senzor, a nije aktiviran prvi senzor zaustavi tajmer
5. Zaustavljanje tajmera i zapisivanje proteklog vremena.

Na osnovu ovih jednostavnih koraka PLC mjeri potrebno vrijeme. PLC, odnosno aktivacija tajmera pokrenuti su istim signalom sa prvog senzora blizine u istom trenutku kao i akvizicija slike čime se osigurava usklađenost mjerenja.

## 6.6 Rezultati mjerenja

Proces mjerenja je završna faza u procjeni kretanja predmeta rada vizijskim sustavom. Nakon izvršenog procesa mjerenja slijedi analiza rezultata. U ovoj fazi biti će vidljivo da li je rasipanje rezultata mjerenja stabilno i može li se upotrijebiti kao konstanta sa kojom se može dalje računati.




Slika 6.19 Grafički prikaz rasipanja rezultata mjerenja puta

Ideja je bila izvršiti procjenu kretanja predmeta rada vizijskim sustavom kako bi se u nekom kasnijem proizvoljnom vremenskom trenutku moglo znati gdje će se predmet rada nalaziti i kako bi robot koji vrši interakciju sa predmetom rada mogao pravovremeno započeti svoje gibanje prema predmetu rada. Na taj način ostvaruje se interakcija robota i predmeta u ključnom trenutku. Upravo je taj trenutak interakcije ključan i o rezultatima mjerenja ovisi hoće li se interakcija moći izvesti sa dovoljnom preciznošću.

Nakon izvedenog mjerenja dobiveni su rezultati koji prikazuju računanje puta vizijskim sustavom (Slika 6.19). Vidljivo je da srednja vrijednost izračunatog puta za dane uvijete iznosi 92 mm. To je put koji predmet rada prijeđe od akvizicije prve slike do akvizicije druge slike. Uočljivo je da je rasipanje rezultata unutar stabilnih granica, pri čemu maksimalna vrijednost rasipanja iznosi 4.321 mm što je dobiveno nakon stotinu mjerenja. Dobiveni rezultat ne ovisi samo u varijaciji vremena potrebnog vizijskom sustavu da obradi sliku već i o oscilacijama u brzini pokretne trake koja dostavlja predmet rada.

Vrijeme



Slika 6.20 Grafički prikaz rasipanja rezultata mjerenja vremena

Rezultati mjerenja vremena između aktivacije senzora pokazuju da je mjerena vrijednost vrlo stabilna, odnosno da vrijednost mjerenja ne oscilira značajno. Vidljivo je da srednja vrijednost mjerenja iznosi 3.235 sekundi. To je vrijeme koje je potrebno da prvi senzor pokrene tajmer, a drugi senzor da zaustavi mjerenje. Vidljivo je da je rasipanje mjerenja unutar vrlo uskog područja pri čemu maksimalna vrijednost rasipanja iznosi 0.092 sekundi. To je iznos koji se niti ne uzima kao vrijednost sa kojom se računa, budući da je navedena vrijednost vjerojatno razlika u oscilacijama signala sa senzora i procesiranja unutar sustava. Zaključuje se da se vrijednost mjerenja vremena može proglasiti konstantom.

Na osnovu prethodnih mjerenja mogu se izračunati potrebni parametri. Vizijijski sustav, kako je prethodno navedeno, računa prijeđeni put. Na osnovu prijeđenog puta i vremena koje je definirano unutar vizijijskog sustava, a koje definira vrijeme između dvije akvizicije (0.15 sekundi) vizijijski sustav računa brzinu predmeta rada.

$$s_{VS} \text{ srednje} = 92 \text{ mm}$$

$$t_{VS} \text{ zadano} = 0.15 \text{ s}$$

$$v_{VS} \text{ srednje} = \frac{s_{VS}}{t_{VS}} = 613.13 \text{ mm/s} \quad (6.1)$$

Dobivena vrijednost je netočna i ukazuje na to da vizijijski sustav treba više od 0.15 sekundi da izvrši akviziciju i obradu dvije slike. Stoga će se upotrijebiti rezultat objektivnog mjerenja koje je izvršeno pomoću kontrolera Allen Bradley kako bi se došlo do točnog iznosa brzine predmeta rada. Udaljenost koja je upotrijebljena, a iznosi 700 mm predstavlja međusobnu udaljenost senzora.

$$s \text{ mjereno} = 700 \text{ mm}$$

$$t \text{ mjereno} = 3.235 \text{ s}$$

$$v = \frac{s}{t} = 216.4 \text{ mm/s} \quad (6.2)$$

Stvarna brzina gibanja predmeta rada je višestruko manja od one koju je računao vizijijski sustav iz čega se zaključuje da vrijeme procesiranja vizijijskog sustava gotovo tri puta veće od onog koje je definirano. Pomoću dobivenih rezultata možemo izračunati objektivno vrijeme procesiranje vizijijskog sustava.

$$t_{VS} \text{ procesiranje} = \frac{s_{VS}}{v} = 0.425 \text{ s} \quad (6.3)$$

Dobiveni rezultat predstavlja, kako je navedeno, objektivno vrijeme procesiranja te se uvrštavanjem navedenog vremena procesiranja u izvorni algoritam dobiva realna brzina predmeta, a time i ostali parametri.

$$v_{VS} \text{ objektivno} = \frac{s_{VS}}{t_{VS} \text{ procesiranje}} = 216.46 \text{ mm/s} \quad (6.4)$$

Na opisani način uz korištenje izračunatog odstupanja, te uvrštavanjem dobivene vrijednosti u vizijski sustav, možemo konačne rezultate koristiti za dinamičko upravljanje robotom ako za danu aplikaciju konačna točnost zadovoljava.

## 7. ZAKLJUČAK

Gledajući kapacitet sustava mozak-oko, trenutni umjetni vizijski sustavi su jednostavno primitivni. Raspon objekata koje mogu percipirati, brzina interpretacije i osjetljivost na svjetlosne probleme te različitosti u teksturama i reflektivnosti objekata su neki od primjera ograničenja trenutne tehnologije. S druge strane, strojni vid ima jasne prednosti kada se radi o kapacitetu rada pri visokim brzinama. Umjetni sustavi mogu vršiti razne zadatke i inspekcije u gototvo simultanom načinu na istom objektu ili na različitim objektima. Ako se dodaju višestruki senzori mogu se čak izvršavati radnje na različitim proizvodnim linijama. Ljudski vid je aktivnost koja uključuje paralelno procesiranje. Sadržaj scene uzima se i pohranjuje simultano. Sa druge strane strojni vid je serijski sustav. Zbog načina funkcioniranja senzora za akviziciju slike, analiza scene se razlaže na niz serijskih operacija pri čemu dobivamo polja podataka po jedinici vremena. Zaključno, jasno je da ljudski vid stvara percepciju slike i donosi zaključke na osnovu onoga što je prethodno naučeno i stavljeno u određene kontekstualne odnose, te se analize donose na osnovu prethodno naučenih modela i obrazaca kako bi se moglo reagirati u pravilnom kontekstu. U tom aspektu pred umjetnim vizijskim sustavima još je dug put.

Vizijski procesi u industrijskoj primjeni su postali nezamjenjivi. Vizijski sustavi izvršavaju zadaće koje čovjek ne može. Najčešće se radi o zadacima praćenja predmeta, prepoznavanja, mjerenja i slično. To su zadatci koji zahtijevaju visoku točnost i koje ujedno čovjek nije u stanju raditi ili nije u stanju pouzdano izvršavati spomenute zadaće zbog repetitivnosti ili brzine procesa. Stoga se takvi problemi rješavaju vizijskim sustavima. Razumljivo je da je ključni parametar u navedenim zadaćama točnost kako bi rezultati mjerenja vizijskih sustava bili referentni. Da bi podatci imali utjecaj na proizvodnju moraju biti što je više moguće točni i precizni. Kada su pravilno implementirani, vizijski sustavi mogu automatizirati akviziciju podataka te mogu služiti kao referenca u kontroli procesa. Snimanjem tih podataka automatski, izravno sa vizijskih sustava ulazne greške su značajno smanjene, a ljudska interakcija minimizirana.

Pomoću vizijskog sustava National Instruments NI CVS 1450 izvršen je zadatak procjene kretanja predmeta rada. Vizijski sustav je pokazao određene nedostatke prilikom izvršavanja ove zadaće. Jedan od glavnih problema je bila softverska nekompatibilnost i dostupnost alata za izradu inspekcija na vizijskom sustavu. Zbog nemogućnosti izvršavanja svih zadataka vizijskim sustavom, zadatak mjerenja vremena izvršen je na kontroleru Allen Bradley kako bi se dobio objektivan uvid u proteklo vrijeme. Pomoću navedenog sustava došlo se do objektivnih rezultata pomoću kojih se izračunao korekcijski faktor. Izračunati korekcijski faktor tada je primjenjen na rezultatima koje generira vizijski sustav kako bi se došlo do objektivnih procjena kretanja rada pomoću vizijskog sustava. Mjerenja su pokazala da su prikupljeni rezultati objektivnog mjerenja vremena senzorima iznimno stabilni i da se mogu koristiti kao referentna vrijednost prilikom izračuna. S druge strane, mjerenja koja je vršio vizijski sustav bila su daleko od idealnih. Izračunati put je varirao unutar nekoliko milimetara te je tek potrebno

utvrditi da li se ostvarena točnost može primjeniti za dinamičko upravljanje robotom pri izvođenju operacija sklapanja. Nadalje, izračunata brzina predmeta do koje se došlo pomoću prijednog puta kojeg je računao vizijski sustav i vremena između akvizicije dvije slike, a koje je točno definirano unutar vizijskog sustava, pokazuje iznimno veliku grešku te daje rezultat koji je potpuno neupotrebljiv. Takva greška rezultat je vremena procesiranja vizijskog sustava. Grešku mjerenja puta pomoću vizijskog sustava možemo svesti na minimum budući da je sustav kalibriran i jednostavnim pregledom se ustvrdilo da je izračunati put objektivn. Primjenom korekcijskog faktora se greška u računanju brzine vizijskim sustavom dovodi u granice tolerancija pa i taj podatak postaje eventualno upotrebljiv.

Može se zaključiti da se navedena odstupanja i pogreške vizijskog sustava daljnjim koracima mogu minimizirati. Kada bi se kamera više udaljila od predmeta rada, što prilikom ove analize nije bilo moguće izvesti, dobio bi se veći kadar te bi mjerenje puta bilo preciznije i stabilnije. Nadalje, primjenom vizijskog sustava sa zasebnim procesiranjem, a ne integriranog vizijskog sustava, vremena procesiranja bila bi manja. Isto tako primjenom softverskog paketa kao što je LabVIEW umjesto integriranih rješenja (VBA) bi odstupanja bila manja te bi se izbjegla potreba za zasebnim sustavom koji mjeri vrijeme između aktivacije pojedinih senzora. Sve navedene promjene bi rezultirale rezultatima sa manje odstupanja te bi eventualna primjena vizijskog sustava za dinamičko upravljanje robotom bila još prikladnija.

# LITERATURA

- [1] Zuech, N., Understanding and applying machine vision, Marcel Dekker, New York, 2006.
- [2] Jähne, B., Haußecker, H., Geißer, P.: Handbook of computer vision and applications, Academic Press, London, 1999.
- [3] Hornberg, A.: Handbook of machine vision, Wiley-VCH, Weinheim, 2006.
- [4] Nixon, M., Aguado, A.: Feature extraction and and image processing, Elsever, London, 2008.
- [5] Sonka, M., Hlavac, V., Boyle, R.: Image preocesing, analysis, and machine vision, Thomson, 2008.
- [6] Priručnik – NI Vision – NI Vision concepts manual
- [7] Specifikacijski katalog – Basler Scout scA1000-20gm/gc - <http://www.baslerweb.com/beitraege>
- [8] Specifikacijski katalog – National Instruments NI CVS 1450 - <http://sine.ni.com/nips/cds>
- [9] Specifikacijski katalog – National Instruments I/O Terminal and Acessory Block - [digital.ni.com/manuals.nsf](http://digital.ni.com/manuals.nsf)
- [10] Priručnik – NI Vision – NI Vision for automated inspection tutorial